

UNIVERSIDADE FEDERAL DO PARANÁ

ALINE SCABURI

OTIMIZAÇÃO NA LOGÍSTICA DE DISTRIBUIÇÃO DE MERCADORIAS POR MEIO
DO PROBLEMA DE ROTEAMENTO DE VEÍCULOS: UM ESTUDO DE CASO PARA
ENTREGA DE JORNAIS

CURITIBA

2020

ALINE SCABURI

OTIMIZAÇÃO NA LOGÍSTICA DE DISTRIBUIÇÃO DE MERCADORIAS POR MEIO
DO PROBLEMA DE ROTEAMENTO DE VEÍCULOS: UM ESTUDO DE CASO PARA
ENTREGA DE JORNAIS

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Produção, na área de Pesquisa Operacional na linha de Métodos de Pesquisa Operacional à Engenharia de Produção, Universidade Federal do Paraná, como requisito parcial à obtenção do grau de Mestre em Engenharia de Produção.

Orientadora: Prof.^a Dr.^a Maria Teresinha Arns Steiner.

CURITIBA

2020

Catálogo na Fonte: Sistema de Bibliotecas, UFPR
Biblioteca de Ciência e Tecnologia

S277o

Scaburi, Aline

Otimização na logística de distribuição de mercadorias por meio do problema de roteamento de veículos: um estudo de caso para entrega de jornais [recurso eletrônico] /Aline Scaburi. – Curitiba, 2019.

Dissertação - Universidade Federal do Paraná, Setor de Tecnologia, Programa de Pós-Graduação em Engenharia da Produção, 2019.

Orientadora: Maria Teresinha Arns Steiner.

1. Logística. 3. Programação heurística. 4. Otimização combinatória. 5. Distribuição de mercadorias. I. Universidade Federal do Paraná. II. Steiner, Maria Teresinha Arns. III. Título.

CDD: 519.64

Bibliotecária: Vanusa Maciel CRB- 9/1928

TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em ENGENHARIA DE PRODUÇÃO da Universidade Federal do Paraná foram convocados para realizar a arguição da dissertação de Mestrado de **ALINE SCABURI** intitulada: **OTIMIZAÇÃO NA LOGÍSTICA DE DISTRIBUIÇÃO DE MERCADORIAS POR MEIO DO PROBLEMA DE ROTEAMENTO DE VEÍCULOS: UM ESTUDO DE CASO PARA ENTREGA DE JORNAIS**, sob orientação da Profa. Dra. MARIA TERESINHA ARNS STEINER, que após terem inquirido a aluna e realizada a avaliação do trabalho, são de parecer pela sua aprovação no rito de defesa.

A outorga do título de mestre está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

CURITIBA, 18 de Fevereiro de 2020.



MARIA TERESINHA ARNS STEINER

Presidente da Banca Examinadora (UNIVERSIDADE FEDERAL DO PARANÁ)



MARIANA KLEINA

Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)



ARINEI CARLOS LINDBECK DA SILVA

Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)



PAULO HENRIQUE SIQUEIRA

Avaliador Externo (UNIVERSIDADE FEDERAL DO PARANÁ)

RESUMO

A melhoria dos processos de distribuição logística representa uma grande área de interesse das empresas tendo em vista as possibilidades de redução dos custos envolvidos. Muitas vezes, as empresas são incapazes de determinar de maneira ótima as rotas a serem percorridas para realizar as coletas e/ou entregas de suas mercadorias, gerando custos adicionais, deslocamentos desnecessários, tempos de entrega prolongados e insatisfação dos clientes. Diante deste contexto, o objetivo deste trabalho é apresentar uma metodologia para a otimização de problemas de distribuição de mercadorias, ou seja, para resolução de Problemas de Roteamento de Veículos (PRV). Uma abordagem, em duas etapas, baseada na utilização do Problema de Localização de Facilidades (PLF) e do Problema do Caixeiro Viajante Assimétrico (PCVA) é proposta para a obtenção das referidas rotas. A fim de verificar a eficiência do método proposto, o mesmo será aplicado na otimização dos roteiros realizados pelos entregadores de uma empresa de jornais no município de Curitiba, visando comparar procedimentos exatos, heurísticos e meta-heurísticos com a solução atual adotada pela empresa. Para isso, fez-se uso das heurísticas: Gillet & Johnson, método de aproximação de Vogel, *First-Fit*, *First-Fit Decreasing*, método dos *Savings* de Clark e Wright e métodos de Inserção. E também dos procedimentos meta-heurísticos: Algoritmo Genético (AG) e Recozimento Simulado ou *Simulated Annealing* (SA). Como resultado este trabalho apresenta um comparativo, entre 40 combinações de métodos diferentes, em termos de qualidade de solução e tempo de processamento computacional, para resolução do estudo de caso em questão e de instâncias da literatura do PLF e do PCVA. Os resultados obtidos para as instâncias da literatura mostram que os procedimentos meta-heurísticos apresentaram melhores resultados em relação à qualidade de solução que os procedimentos heurísticos para o PLF e para o PCVA. No que se refere ao tempo de processamento computacional, para o PLF os procedimentos meta-heurísticos têm um tempo menor enquanto para o PCVA o tempo de processamento das meta-heurísticas é superior. No estudo de caso, o melhor resultado obtido mostra que é possível, por meio do método Algoritmo Genético para a fase 1 (PLF) e fase 2 (PCVA), uma redução de aproximadamente 36,54% no deslocamento do entregador em comparação à solução atual adotada pela empresa, refletindo uma possibilidade de redução de custo.

Palavras-chave: Otimização. Roteirização. Problema de Localização de Facilidades (PLF). Problema do Caixeiro Viajante (PCV), Heurísticas, Meta-Heurísticas.

ABSTRACT

Improving logistics distribution processes is a major area of interest for companies that have in view the possibilities for reducing the costs involved. Often, companies are unable to optimally determine the routes to be taken to collect and / or deliver their goods, generating additional costs, unnecessary travel, prolonged delivery times and customer unsatisfaction. Given this context, the objective of this work is to present a methodology for the optimization of merchandise distribution problems, that is, for solving Vehicle Routing Problems (VRP). A two-step approach, based on the use of the Facility Location Problem (FLP) and the Asymmetric Traveling Salesman Problem (ATSP) is proposed to obtain the referred routes. In order to verify the efficiency of the proposed method, it will be applied in the optimization of the routes carried out by the deliverers of a newspaper company in the city of Curitiba, aiming to compare exact, heuristic and meta-heuristic procedures with the current solution adopted by the company. For this, heuristics were used: Gillet & Johnson, the Vogel approach method, First-Fit, First-Fit Decreasing, Clark and Wright's Savings method and Insertion methods. And also, the meta-heuristic procedures: Genetic Algorithm (GA) and Simulated Annealing (SA). As a result, this work presents a comparison, between 40 combinations of different methods, in terms of solution quality and computational processing time, for solving the case study in question and FLP and ATSP instances. The results obtained for the instances show that the meta-heuristic procedures presented better results in relation to the solution quality than the heuristic procedures for FLP and for ATSP. Regarding the computational processing time, for the FLP the meta-heuristic procedures have a shorter time while for the ATSP the processing time of the meta-heuristics is longer. In the case study, the best result obtained shows that it is possible, through the Genetic Algorithm method for phase 1 (FLP) and phase 2 (ATSP), a reduction of approximately 36.54% in the displacement of the delivery man compared to the solution adopted by the company, reflecting the possibility of cost reduction.

Keywords: Optimization. Routing. Facility Location Problem (FLP). Assymmetric Traveling Salesman Problem (ATSP), Heuristics, Meta-Heuristics.

AGRADECIMENTOS

Em primeiro lugar agradeço aos meus pais, João e Adelaide, que sempre me incentivaram a estudar e me apoiaram durante toda caminhada escolar! Também a minha irmã Paula, que sempre me instigou a buscar mais. Sem vocês eu não teria chegado tão longe.

Agradeço por todo apoio e incentivo do meu namorado Irineu, desde o momento da inscrição no processo seletivo e principalmente durante esses dois anos.

Agradeço ao amigo Júlio Cesar Ferreira que me auxiliou muito durante esses dois anos nessa caminhada rumo ao desconhecido (artigos, congressos, jornais científicos!!). Sempre atencioso, disponível e disposto a ajudar com o que fosse preciso!

Agradeço a minha orientadora, Prof^a. Dr^a. Maria Teresinha Arns Steiner, pela sua primorosa e impecável orientação, competência, dedicação, paciência, profissionalismo e por acreditar no meu potencial. Também por ser minha inspiração em modelo de professora e pesquisadora!

Agradeço a todos os professores pelos conhecimentos transmitidos, tanto os do mestrado e aos de minha graduação que me incentivaram a encarar este desafio.

Agradeço aos meus colegas da turma de Mestrado pela amizade, caronas, parceria, ajuda mutua e troca de conhecimentos. Vocês foram fundamentais para que este Mestrado fosse concluído!

LISTA DE FIGURAS

FIGURA 1 - REGIÃO ATUAL DE ENTREGAS ATENDIDA PELA EMPRESA ABC..	22
FIGURA 2 - ETAPAS DO PROCESSO DE IMPRESSÃO E DISTRIBUIÇÃO DOS JORNAIS.....	24
FIGURA 3 - LOCALIZAÇÃO DOS 194 PONTOS DE ENTREGA DO ROTEIRO 1010002	25
FIGURA 4 - RELAÇÃO ENTRE 194 PONTOS DE ENTREGA E 35 MACRO PONTOS DE DEMANDA	27
FIGURA 5 - RELAÇÃO DA DEMANDA POR MACRO PONTO	28
FIGURA 6 - ILUSTRAÇÃO DAS ROTAS EMPREGADAS ATUALMENTE PELO DISTRIBUIDOR	29
FIGURA 7 - ETAPAS DO PROCESSO DE PESQUISA.....	30
FIGURA 8 - DEFINIÇÃO DAS ENTRADAS NOS MOTORES DE BUSCA	31
FIGURA 9 - FLUXOGRAMA DA FILTRAGEM DOS ARTIGOS	33
FIGURA 10 - NUVEM DE PALAVRAS GERADA A PARTIR DOS ARTIGOS DA AMOSTRA	43
FIGURA 11 - PASSOS DO ALGORITMO HEURÍSTICO DE T&B	63
FIGURA 12 - PASSOS DO ALGORITMO DE GILLET E JOHNSON MODIFICADO	64
FIGURA 13 - PASSOS DO ALGORITMO DE VOGEL.....	64
FIGURA 14 - ILUSTRAÇÃO DE ROTA EM UM PCV E DE MÚLTIPLAS ROTAS EM UM PRV	66
FIGURA 15 - ILUSTRAÇÃO DO CONCEITO DE ECONOMIA	70
FIGURA 16 - PASSOS DO ALGORITMO DOS SAVINGS DE C&W	71
FIGURA 17 - PASSOS DO ALGORITMO DE INSERÇÃO DO MAIS PRÓXIMO.....	71
FIGURA 18 - PASSOS DO ALGORITMO DE INSERÇÃO DO MAIS BARATO.....	72
FIGURA 19 - PASSOS DO ALGORITMO DE INSERÇÃO RÁPIDA OU VIZINHO MAIS PRÓXIMO	72
FIGURA 20 - PSEUDOCÓDIGO DA HEURISTICA DE MELHORIAS DE ROTAS k -OPT.....	73
FIGURA 21 - ALTERNATIVAS DE MOVIMENTO EM UM MELHORIA 2-OPT.....	73
FIGURA 22 - ALTERNATIVAS DE MOVIMENTO EM UM MELHORIA 3-OPT.....	74
FIGURA 23 - RELAÇÃO DA REPRESENTAÇÃO GENÉTICA EM UM AG	75

FIGURA 24 - PSEUDOCÓDIGO DA META-HEURÍSTICA ALGORITMO GENÉTICO	76
FIGURA 25 - EXEMPLOS DO OPERADOR DE MUTAÇÃO EM UM PROBLEMA DE CODIFICAÇÃO POR PERMUTAÇÃO	78
FIGURA 26 - PSEUDOCÓDIGO DA META-HEURÍSTICA SIMULATED ANNEALING	81
FIGURA 27 - CARACTERIZAÇÃO METODOLÓGICA DESTA PESQUISA	83
FIGURA 28 - ABORDAGEM DA PESQUISA OPERACIONAL PARA RESOLUÇÃO DE PROBLEMAS	84
FIGURA 29 - ABORDAGEM DE RESOLUÇÃO EM DUAS ETAPAS	86
FIGURA 30 - ROTAS ÓTIMAS EM FUNÇÃO DE PARÂMETROS DE CUSTO DIFERENTES	87
FIGURA 31 - PROCEDIMENTOS EXATOS, HEURÍSTICOS E META-HEURÍSTICOS A SEREM APLICADOS E SUAS POSSÍVEIS COMBINAÇÕES	88
FIGURA 32 - AGRUPAMENTO DOS 35 MACRO PONTOS DE DEMANDA PELA ABORDAGEM I	94
FIGURA 33 - REPRESENTAÇÃO DAS 5 ROTAS OBTIDAS DE FORMA EXATA	95
FIGURA 34 - REPRESENTAÇÃO DAS 5 ROTAS OBTIDAS PELO ALGORITMO GENÉTICO	98
FIGURA 35 - REPRESENTAÇÃO DOS DESLOCAMENTOS REAIS DE CADA ROTA OBTIDA PELO ALGORITMO GENÉTICO	99

LISTA DE GRÁFICOS

GRÁFICO 1 - DISTRIBUIÇÃO AO LONGO OS ANOS DOS ARTIGOS LEVANTADOS	35
GRÁFICO 2 - ANÁLISE DOS 10 PRINCIPAIS PERIÓDICOS	36
GRÁFICO 3 - PRINCIPAIS PAÍSES DE DESENVOLVIMENTO DAS PESQUISAS	37
GRÁFICO 4 - MÉTODOS DE RESOLUÇÃO IDENTIFICADOS NA AMOSTRA	41
GRÁFICO 5 - TÉCNICAS DE RESOLUÇÃO AGRUPADAS POR CATEGORIAS	41
GRÁFICO 6 - SOFTWARES / LINGUAGENS DE PROGRAMAÇÃO EMPREGADAS	42
GRÁFICO 7 - RELAÇÃO ENTRE DISTÂNCIA TOTAL E TEMPO DE PROCESSAMENTO PARA CADA MÉTODO DE RESOLUÇÃO.....	106

LISTA DE QUADROS

QUADRO 1 - MÉTODOS DE RESOLUÇÃO EMPREGADOS NA AMOSTRA.....	37
QUADRO 2 - RESUMO DAS PUBLICAÇÕES RELACIONADAS AO TEMA DA PESQUISA.....	55

LISTA DE TABELAS

TABELA 1 - RELAÇÃO DOS 35 MACRO PONTOS DE DEMANDA	26
TABELA 2 - ROTAS ATUALMENTE EMPREGADAS PARA ATENDIMENTO DO ROTEIRO 1010002.....	28
TABELA 3 - ARTIGOS MAIS RELEVANTES CONSIDERANDO AS CITAÇÕES RECEBIDAS	34
TABELA 4 - ROTAS ÓTIMAS EM RELAÇÃO AOS DIFERENTES PARÂMETROS BASE DE CUSTO	88
TABELA 5 - DADOS DAS 5 ROTAS OTIMIZADAS OBTIDAS PELA ABORDAGEM I	95
TABELA 6 - VALORES DE FO PARA O PLF OBTIDOS PELOS DIFERENTES MÉTODOS HEURÍSTICOS DE AGRUPAMENTO.....	96
TABELA 7 - DISTÂNCIA TOTAL DE DESLOCAMENTO PARA ENTREGAS OBTIDA POR MÉTODOS HEURÍSTICOS EM FUNÇÃO DOS DIFERENTES MÉTODOS DE AGRUPAMENTO	96
TABELA 8 - DISTÂNCIA TOTAL DE DESLOCAMENTO PARA ENTREGAS OBTIDA POR MÉTODOS META-HEURÍSTICOS EM FUNÇÃO DOS DIFERENTES MÉTODOS DE AGRUPAMENTO	97
TABELA 9 - VALORES DE FO PARA O PLF OBTIDOS PELOS MÉTODOS META- HEURÍSTICOS DE AGRUPAMENTO.....	97
TABELA 10 - DISTÂNCIA TOTAL DE DESLOCAMENTO PARA ENTREGAS OBTIDA POR MÉTODOS META-HEURÍSTICOS EM FUNÇÃO DOS DIFERENTES MÉTODOS DE AGRUPAMENTO	98
TABELA 11 - RESULTADO DAS TÉCNICAS RELACIONADAS AO PLF CAPACITADO PARA AS INSTÂNCIAS DA LITERATURA.....	101
TABELA 12 - RESULTADO DAS TÉCNICAS RELACIONADAS AO PCVA PARA AS INSTÂNCIAS DA LITERATURA	104
TABELA 13 - VALORES MÉDIOS POR CATEGORIA EM FUNÇÃO DO NÚMERO DE PONTOS PARA INSTÂNCIA DO PLF	108
TABELA 14 - RESULTADOS MÉDIOS POR MÉTODO DE RESOLUÇÃO APLICADOS AS INSTÂNCIAS DO PLF	108
TABELA 15 - VALORES MÉDIOS POR CATEGORIA EM FUNÇÃO DO NÚMERO DE PONTOS PARA INSTÂNCIA DO PCVA.....	109

TABELA 16 - RESULTADOS MÉDIOS POR MÉTODO DE RESOLUÇÃO APLICADOS AS INSTÂNCIAS DO PCVA	109
--	-----

LISTA DE ABREVIATURAS OU SIGLAS

ABO	- Otimização do Búfalo-africano
ACO	- <i>Ant Colony Optimization</i>
AG	- Algoritmo genético
BT	- Busca Tabu
C&K	- Clarke e Wright
DA	- <i>Deterministic approximation</i>
DP	- <i>Dynamic Programming</i>
FLP	- <i>Facility Location Problem</i>
FLP	- <i>Facility Location Problem</i>
FO	- Função Objetivo
GEE	- Gases de Efeito Estufa
GP	- <i>Goal Programming</i>
GRASP	- <i>Greedy randomized adaptive search procedures</i>
IBGE	- Instituto Brasileiro de Geografia e Estatística
ILP	- <i>Integer Linear Programming</i>
ILS	- <i>Iterated local search</i>
JCR	- <i>Scimago Journal & Country Rank</i>
LINGO	- <i>Language for Interactive Optimizer Systems</i>
LP	- <i>Linear Programming</i>
LS	- <i>Local Search</i>
MILP	- <i>Mixed integer linear programming</i>
MIP	- <i>Mixed Integer Programming</i>
NNS	- <i>Nearest Neighbor Search</i>
PCV	- Problema do Caixeiro Viajante
PCVA	- Problema do Caixeiro Viajante Assimétrico
PLF	- Problema de Localização de Facilidades
PLIB	- Programação Linear Inteira Binária
PLIM	- Programação Linear Inteira Mista
PMCV	- Problema dos Múltiplos Caixeiros Viajantes
PO	- Pesquisa Operacional
PRV	- Problema de Roteirização de Veículos
PSO	- <i>Particle Swarm Optimization</i>

SA	- <i>Simulated annealing</i>
T&B	- Teitz e Bart
TSP	- <i>Traveling Salesman Problem</i>
TSPLIB	- <i>Traveling Salesman Problem Library</i>
VNS	- <i>Variable Neighborhood Search</i>
VRP	- <i>Vehicle Routing Problem</i>

SUMÁRIO

1 INTRODUÇÃO	18
1.1 JUSTIFICATIVA	19
1.2 OBJETIVOS	20
1.2.1 Objetivo geral	20
1.2.2 Objetivos específicos.....	20
1.3 DELIMITAÇÃO DO TEMA.....	20
1.4 ESTRUTURA DO TRABALHO	21
2 DESCRIÇÃO DO PROBLEMA.....	22
2.1 CONDIÇÃO ATUAL DE ROTEIRIZAÇÃO	25
3 REVISÃO DE LITERATURA	30
3.1 REVISÃO BIBLIOMÉTRICA E SISTEMÁTICA DA LITERATURA	30
3.1.1 Definição da amostra.....	30
3.1.2 Análise Bibliométrica	34
3.1.3 Análise Sistemática	37
3.2 TRABALHOS CORRELATOS	43
3.3 FUNDAMENTAÇÃO TEÓRICA.....	58
3.3.1 Pesquisa Operacional e Otimização Combinatória	58
3.3.2 Problema de Localização de Facilidades – PLF.....	59
3.3.2.1 Procedimento Exato para o PLF.....	60
3.3.2.2 Procedimentos Heurísticos para o PLF	61
A. Algoritmo das p -medianas de Teitz & Bart (T&B).....	61
B. Algoritmo de Gillett e Johnson Modificado.....	63
C. Algoritmo de Vogel	64
D. Algoritmo <i>First-Fit</i> (FF).....	65
E. Algoritmo <i>First-Fit-Decreasing</i> (FFD).....	65
3.3.3 Problema do Caixeiro Viajante – PCV.....	65
3.3.3.1 Modelo Matemático	67
3.3.3.2 Procedimentos Heurísticos para o PCV	69
A. Procedimentos de Construção de Rotas	70
B. Procedimentos de Melhoria de Rotas.....	73
3.3.4 Procedimentos Meta-heurísticos para o PLF e para o PCV	74
3.3.4.1 Algoritmo Genético	74

3.3.4.2 <i>Simulated Annealing</i>	78
4 METODOLOGIA	82
4.1 CARACTERIZAÇÃO DA METODOLOGIA DE PESQUISA.....	82
4.2 ETAPAS DO PROCEDIMENTO METODOLÓGICO	84
4.3 MÉTODO PROPOSTO PARA RESOLUÇÃO DO PROBLEMA	85
4.4 ESPECIFICIDADES DOS PROCEDIMENTOS ADOTADOS.....	89
4.4.1 <i>First-Fit</i> e <i>First-Fit-Decreasing</i>	89
4.4.2 Algoritmo genético para o PLF	89
4.4.3 Algoritmo genético para o PCVA.....	90
4.4.4 <i>Simulated Annealing</i> para o PLF	91
4.4.5 <i>Simulated Annealing</i> para o PCVA.....	92
5 RESULTADOS.....	93
5.1 ABORDAGEM I – AGRUPAMENTO EXATO (PLF) COM ROTEAMENTO EXATO (PCVA)	93
5.2 ABORDAGEM II - AGRUPAMENTO HEURÍSTICO (PLF) COM ROTEAMENTO HEURÍSTICO (PCVA)	95
5.3 ABORDAGEM III - AGRUPAMENTO HEURÍSTICO (PLF) COM ROTEAMENTO META-HEURÍSTICO (PCVA).....	97
5.4 ABORDAGEM IV - AGRUPAMENTO META-HEURÍSTICO (PLF) COM ROTEAMENTO META-HEURÍSTICO (PCVA).....	97
5.5 INSTÂNCIAS DA LITERATURA.....	99
5.5.1 Instâncias da Literatura aplicado aos algoritmos de resolução do PLF	99
5.5.2 Instâncias da Literatura aplicado aos algoritmos de resolução do PCVA	103
5.6 ANÁLISE DOS RESULTADOS	106
5.6.1 Em relação ao estudo de caso para entrega dos jornais.....	106
5.6.2 Em relação as instâncias da literatura.....	107
6 CONSIDERAÇÕES FINAIS	110
REFERÊNCIAS.....	112
ANEXO 1 – LISTAGEM DOS 89 ROTEIROS ATENDIDOS PELO DISTRIBUIDOR DA REGIÃO SUL	121
ANEXO 2 – MATRIZ DE DISTÂNCIAS DE DESLOCAMENTOS REAIS ENTRE OS 35 MACRO PONTOS DE DEMANDA	123

1 INTRODUÇÃO

Os serviços de transporte desempenham um papel estratégico na economia brasileira, tanto internamente na movimentação de produtos de consumo intermediário e final às empresas e famílias, quanto no mercado externo para escoamento da produção agrícola, mineral e industrial.

Segundo dados da Pesquisa Anual de Serviços realizada pelo IBGE (Instituto Brasileiro de Geografia e Estatística), as atividades do setor de transporte como um todo, ocuparam o primeiro lugar na geração de receita operacional líquida do setor de serviços empresariais não financeiros no ano de 2016¹, respondendo por 28,3% do total com a cifra de R\$ 414,74 bilhões de reais. Adicionalmente, as empresas de transporte terrestre de cargas ocupam o primeiro lugar do grupo de empresas de transporte, sendo responsáveis por 34,6% da Receita Operacional Líquida (correspondendo a 143,6 bilhões de reais) gerada pelo setor que é composto também por empresas de transporte rodoviário de passageiros, aéreo, ferroviário, correio e outras atividades de entregas, aquaviário e empresas de armazenamento e atividades auxiliares aos transportes (IBGE, 2018).

O transporte de mercadorias é a área operacional da logística que posiciona/realoca os produtos de acordo com as necessidades dos usuários. O custo relacionado a esta movimentação é notável, seja pelo emprego de frota própria ou terceirizada. Os sistemas logísticos visam a utilização de transportes que minimizem o custo total, porém buscando obter um equilíbrio entre custo e qualidade do serviço visando obter a satisfação das necessidades dos clientes (BOWERSOX et al., 2014).

Diante da relevância do setor de transportes e da necessidade de estratégias de reduções de custo a longo prazo, o tema desta pesquisa é a otimização no serviço de roteirização de veículos que corresponde a uma grande área de estudos da área de Pesquisa Operacional (PO).

A otimização do processo de roteirização comumente emprega a aplicação do Problema de Roteamento de Veículos (PRV), proposto por Dantzig e Ramser (1959),

¹ Em razão da complexidade para a realização de pesquisas setoriais amplas como a Pesquisa Anual de Serviços, existe um lapso de tempo entre a coleta das informações e a publicação dos resultados. Assim, a última edição divulgada em 2018 corresponde aos dados coletados na pesquisa de 2016 (IBGE, 2018).

que tem grande importância para uma eficaz distribuição logística (VALIDI et al., 2015; POONTHALIR; NADARAJAN, 2018).

Os PRV podem ser resolvidos de diversas maneiras e têm grande aplicação prática como se pode ver em Santos et al. (2016), Braga et al. (2015), Silva (2016), Ferreira et al. (2015), dentre outros. Neste trabalho, será apresentado um método de resolução do PRV baseado na utilização do Problema de Localização de facilidades (PLF) e do Problema do Caixeiro Viajante (PCV), ou seja, em duas fases: 1) definição de *clusters* dentre os pontos de demanda a serem atendidos (PLF); e 2) definição das rotas a serem percorridas dentro de cada *cluster* (PCV).

Este trabalho visa responder a seguinte pergunta: como otimizar a prestação do serviço de entrega aos clientes finais, visando a minimização dos custos e a maximização da satisfação dos clientes?

1.1 JUSTIFICATIVA

De acordo com Cattaruzza et al. (2017), um processo de roteirização otimizado apresenta benefícios para todos os envolvidos. Além disso, tem-se na literatura diversos exemplos demonstrando a possibilidade de redução de gastos envolvidos no processo de transporte de mercadorias, economias que são refletidas em retorno financeiro às organizações como mostrado em Leite e Gomes (2017), Viana e Roboredo (2016) e Sousa e Kloeckner (2017).

Levando em conta o cenário altamente competitivo onde as empresas desempenham suas atividades atualmente, oportunidades de redução de custos constituem uma vantagem competitiva às empresas que venham a aplicar as técnicas que serão apresentadas e propostas.

As empresas de transporte que utilizarem métodos de otimização de rotas, terão possibilidade de atender seus clientes de maneira mais ágil, com custos mais baixos sendo que esta economia pode ser repassada aos clientes, maximizando o desempenho operacional e o lucro da organização. Também, melhorias podem ser observadas da ótica do cliente final, os mesmos poderão ser atendidos de maneira mais rápida e eficiente a um custo mais baixo.

1.2 OBJETIVOS

Nesta seção serão apresentados os objetivos deste presente estudo, divididos em objetivo geral e específicos.

1.2.1 Objetivo geral

O objetivo geral deste trabalho é apresentar uma metodologia para otimização de problemas de distribuição de mercadorias; no caso deste presente estudo, na distribuição de jornais.

1.2.2 Objetivos específicos

Os objetivos específicos podem ser descritos da seguinte forma:

- a) Descrever as técnicas de PO aplicadas ao PLF (ou problema das p -Medianas) e ao PCV para a definição das rotas a serem percorridas por veículos da empresa em questão;
- b) Aplicar as técnicas exata e heurísticas para definição dos agrupamentos dos pontos de demanda (*clusters*);
- c) Aplicar as técnicas exata e heurísticas ao PCV para definição de rotas, isto é, a sequência de pontos de demanda a serem transpassados dentro de cada grupo;
- d) Aplicar os algoritmos propostos para resolução do estudo de caso em Instâncias da Literatura (tanto do PLF quanto do PCV), visando a validação dos mesmos.
- e) Comparar o processo otimizado por meio dos diferentes métodos, com o processo atual da empresa analisada, identificando oportunidades de redução de custos.

1.3 DELIMITAÇÃO DO TEMA

Este trabalho delimita-se a análise e especificação de técnicas da área de PO para a definição de grupos de pontos de atendimento (*clusters*) e a subsequente

roteirização, aplicadas no contexto do serviço de uma empresa de distribuição de jornais dentro do município de Curitiba, Paraná.

1.4 ESTRUTURA DO TRABALHO

Este trabalho possui seis capítulos, incluindo esta introdução onde foram apresentados o tema abordado, os objetivos a serem alcançados com a pesquisa, assim como a justificativa e delimitações do estudo.

O capítulo 2 descreve detalhadamente a situação problema em questão no estudo de caso abordado.

No capítulo 3 foi realizada uma revisão bibliométrica e sistemática da literatura em relação aos temas chaves desta pesquisa, são apresentados os trabalhos correlatos a este estudo e por fim, delimita-se a fundamentação teórica dos temas abordados.

No capítulo 4 tem-se a definição da metodologia de resolução proposta bem como as especificidades de cada um dos métodos utilizados.

No capítulo 5 são apresentados os resultados finais obtidos para o estudo de caso em questão e para as instâncias da literatura selecionadas conjuntamente com a análise dos mesmos. E, por fim, o capítulo 6 apresenta as considerações finais obtidas ao longo da pesquisa realizada.

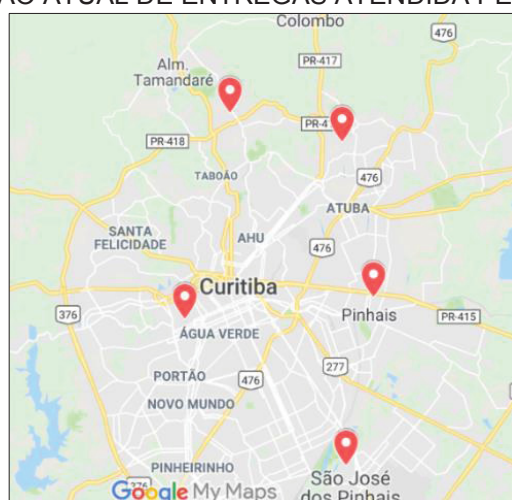
2 DESCRIÇÃO DO PROBLEMA

O estudo de caso será realizado em uma empresa responsável pela distribuição física da edição do fim de semana do jornal impresso de uma grande editora com sede localizada na cidade de Curitiba, estado do Paraná.

A empresa de distribuição, aqui denominada ABC, é responsável pela retirada do material impresso em uma gráfica prestadora de serviço à editora. A editora envia à gráfica o volume semanal, em dois formatos: (1) jornal e (2) caderno especial formato revista, nas quintas-feiras juntamente com o programa de impressão em relação à quantidade de demanda. A gráfica realiza o processo de impressão nas sextas-feiras e a distribuição acontece por meio de distribuidores da empresa ABC que realizam a retirada dos jornais na gráfica, nas sextas-feiras a partir das 14h. Após a retirada dos jornais e revistas na gráfica, o distribuidor tem a função de separar, etiquetar, ordenar, e realizar o processo de distribuição física. As entregas iniciam-se a partir das 21h de sexta-feira e devem ser finalizadas impreterivelmente até às 8h de sábado.

Na FIGURA 1, tem-se o mapa referente a região atual das entregas atendidas pela empresa ABC, que ocorre entre as regiões de Colombo, Curitiba, Almirante Tamandaré, Pinhais e São José de Pinhais, todas no Estado do Paraná representadas pelos marcadores em vermelho na figura.

FIGURA 1 - REGIÃO ATUAL DE ENTREGAS ATENDIDA PELA EMPRESA ABC



FONTE: Adaptado de *Google Maps* (2019).

A fim de organizar o processo de distribuição entre as áreas mencionadas, a empresa ABC adota uma subdivisão em duas regiões, constituídas por dois centros

de distribuição, um para atendimento da região Sul e outro para a região Norte. A média de entregas semanais realizadas pela empresa ABC para assinantes é de 18.000 exemplares enquanto a média de entregas a pontos de venda avulsa (principalmente bancas de jornais) é de 1.400 exemplares.

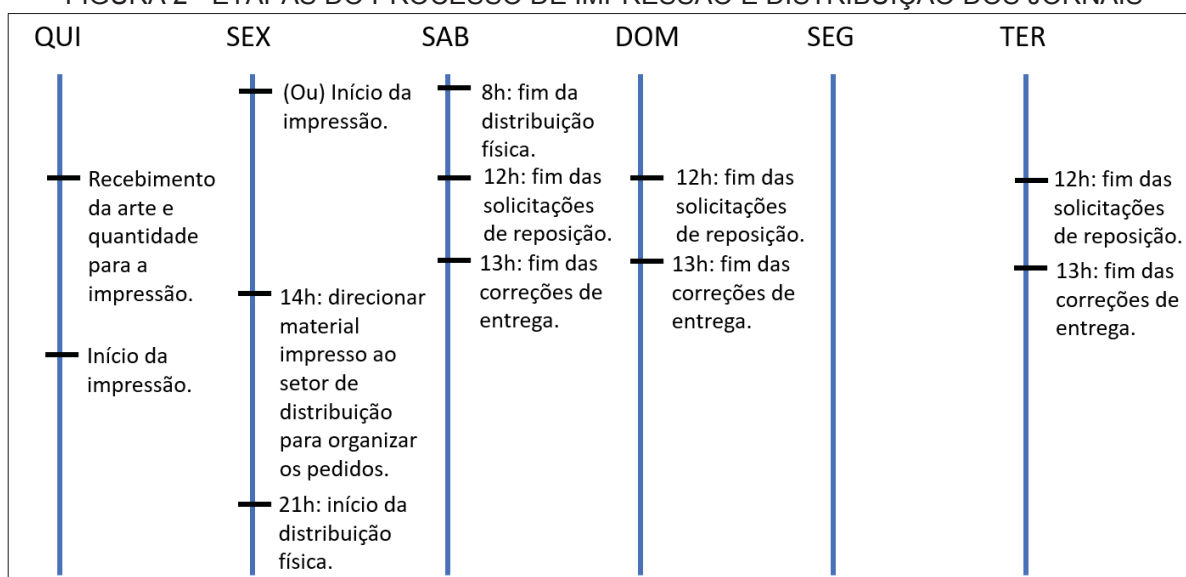
Em relação ao atendimento dos pontos de venda avulsa (bancas de jornais, mercearias, padarias, papelarias entre outros estabelecimentos diversos) além da entrega há adicionalmente o processo de recolher as devoluções dos exemplares que não foram vendidos na semana anterior, que são chamados de “encalhe”. O processo de entrega e recolhimento do “encalhe” ocorre igualmente nas sextas-feiras à noite devendo ser finalizado no sábado na parte da manhã. O mesmo entregador que realiza a entrega dos jornais novos, recolhe as sobras dos não vendidos.

Este trabalho tem foco na otimização das rotas de entrega aos assinantes atendidos pelo centro de distribuição da região Sul, que atualmente realiza a operação com 40 entregadores (*motoboys*), sendo que algumas entregas do roteiro de atendimento ao centro de Curitiba são realizadas por meio de bicicletas, devido à dificuldade de estacionar veículos para a entrega nesta região da cidade.

Cada um dos 40 entregadores recebe, na sexta-feira à noite, uma listagem com os roteiros a serem percorridos para realização das entregas. Os roteiros são baseados na listagem de entregas aos assinantes enviada na quinta-feira pela editora, juntamente com a tiragem. As entregas devem ser finalizadas até às 8h de sábado. Após esse horário, a empresa ABC recebe as solicitações de reposições, referentes a entregas não realizadas, que são enviadas ao distribuidor por meio de *tickets* abertos pela central de atendimento ou diretamente pelo assinante.

Todas as reposições abertas no sábado até 12h devem ser realizadas no mesmo dia até às 13h. Caso as reposições sejam solicitadas após as 12h, serão entregues apenas no domingo até às 12h. Pedidos de reposição abertos a partir de domingo até terça-feira 12h, serão entregues na terça-feira até 13h, e solicitações realizadas após terça-feira 12h, são entregues no próximo final de semana. A cada reposição realizada, a empresa ABC tem um custo de R\$ 2,20, tendo em média 50 reposições por edição, ocorrendo por motivos de não entrega do jornal ou ser entregue em local inadequado como por exemplo gramados molhados, locais “inacessíveis” ao cliente, telhados, entre outros casos reportados. O processo pode ser esquematizado na FIGURA 2, onde tem-se as atividades mencionadas anteriormente relacionadas com o bloco de tempo programado para que sejam executadas.

FIGURA 2 - ETAPAS DO PROCESSO DE IMPRESSÃO E DISTRIBUIÇÃO DOS JORNAIS



FONTE: A autora (2019).

Com base na listagem de entregas enviada semanalmente pela editora, é responsabilidade do distribuidor fazer as etiquetas de identificação para colocar em todos os jornais (ou conjuntos de jornais e revistas) para atendimento das entregas da sua região e montar a divisão dos roteiros utilizados. Por ocasião da pesquisa, o distribuidor da região sul emprega para o atendimento dos assinantes, 89 roteiros diferentes, demonstrados no ANEXO 1, que traz o código de identificação do roteiro, número de assinantes que deverão ser atendidos juntamente com a quantidade de entregas correspondentes a Jornais com revista (JR) ou apenas Jornais (J).

Para as análises e proposta de otimização de rotas, um dos 89 roteiros foi selecionado, o Roteiro: 1010002 da região do Água Verde e Vila Izabel, que conta com 194 diferentes pontos de parada e atende à demanda de 479 volumes impressos, sendo correspondentes a 262 jornais e 217 conjuntos de jornais com revistas. A diferença entre número de pontos de parada e quantidade de itens entregue se deve ao atendimento de assinantes que residem em condomínios e prédios, onde em um mesmo ponto de parada são entregues mais de uma unidade. A localização dos 194 pontos é indicada na FIGURA 3, onde as coordenadas respectivas a cada endereço foram plotadas no mapa com auxílio do ambiente de programação R acessando informações do *Google Maps*.

Para a determinação da localização exata (coordenadas) dos 35 macro pontos foi considerado o primeiro ponto de entrega da rua em questão, assim cada um dos macro pontos se torna a referência para o início das distribuições na respectiva rua. Seguindo esse raciocínio, para as ruas de sentido único foi necessário considerar o sentido da mesma durante o deslocamento do entregador para se determinar dentre os diversos pontos a serem atendidos qual representará o primeiro ponto de entrega. Desta forma, o entregador não precisará fazer uma adequação no roteiro para a distribuição. A TABELA 1 apresenta os 35 respectivos endereços, bem como a demanda agrupada em cada um deles.

TABELA 1 - RELAÇÃO DOS 35 MACRO PONTOS DE DEMANDA

Pontos	Endereços	Demanda
1	Petit Carneiro - Bairro Água Verde	71
2	Saint Hilaire - Bairro Água Verde	8
3	Sebastião Paraná, Prof. - Bairro Vila Izabel	2
4	Sylvio Zeny - Bairro Portão	4
5	Ulisses Vieira - Bairro Vila Izabel	8
6	Vital Brasil - Bairro Portão	1
7	Agostinho Narezi - Bairro Vila Izabel	1
8	Av. Água Verde	6
9	Prof. Álvaro Jorge - Bairro Vila Izabel	13
10	Antônio Pietruza - Bairro Portão	7
11	Arion Niepce Da Silva - Bairro Portão	7
12	Engenheiro Arthur Bettles - Bairro Portão	25
13	Ary Guimarães - Bairro Vila Izabel	1
14	Bororos - Bairro Vila Izabel	5
15	Prof. Brásilio Ovidio Da Costa - Bairro Portão	5
16	Candido Xavier - Bairro Água Verde	10
17	Carneiro Lobo - Bairro Água Verde	26
18	Castro Alves - Bairro Batel	22
19	Professor Dario Velloso - Bairro Vila Izabel	17
20	Eurides Cunha - Bairro Vila Izabel	6
21	Francisco Frischmann - Bairro Portão	9
22	Guianazes - Bairro Vila Izabel	2
23	Guararapes - Bairro Vila Izabel	19
24	Prof. Guido Straube - Bairro Vila Izabel	10
25	Guilherme Pugsley - Bairro Água Verde	21
26	Herculano Carlos Franco De Souza - Bairro Portão	7
27	Joao Geara - Bairro Portão	10
28	Jose Ferreira Pinheiro - Bairro Portão	1
29	Leoncio Correia - Bairro Água Verde	5
30	Morretes - Bairro Portão	7
31	Eng. Niepce Silva - Bairro Portão	29
32	Coronel Ottoni Maciel - Bairro Vila Izabel	25
33	Parintins - Bairro Vila Izabel	10
34	Travessa Percy Wathers - Bairro Água Verde	16
35	V. República Argentina - Bairro Água Verde	63

FONTE: A autora (2019).

A FIGURA 4 ilustra essa situação de agrupamento, onde os pontos em azul representam os macro pontos de demanda, e tem-se também em vermelho a identificação dos 194 pontos já mencionados anteriormente na FIGURA 3. A definição da localização dos macro pontos levando em conta o ponto inicial de entregas da rua em questão, deve-se às características da base de dados, pois em uma mesma rua os pontos de parada não são muito distantes entre si.

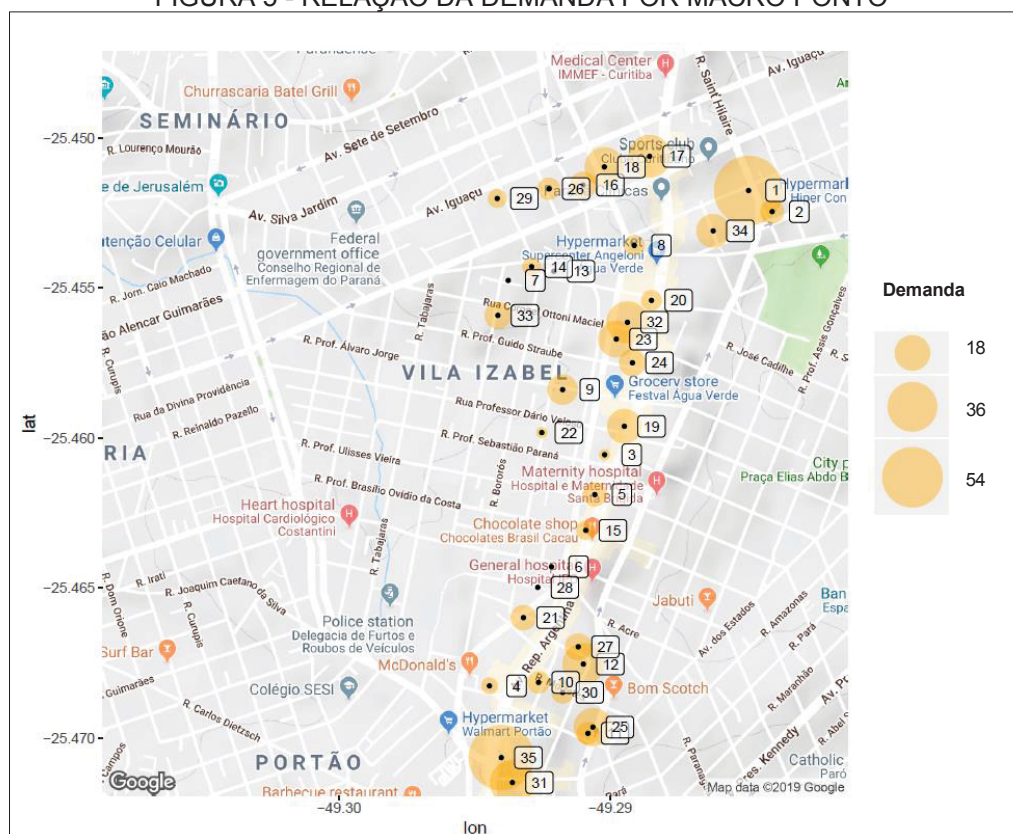
Em relação as quantidades de demanda por macro ponto, a FIGURA 5 apresenta a distribuição da demanda em função da localização dos macro pontos, onde a área sombreada equivale em escala a quantidade de jornais a ser entregue na rua do determinado macro ponto. Pode-se perceber que os pontos com maior quantidade de demanda agrupada são os pontos 1 e 35, correspondendo a 71 e 63 unidades respectivamente.

FIGURA 4 - RELAÇÃO ENTRE 194 PONTOS DE ENTREGA E 35 MACRO PONTOS DE DEMANDA



FONTE: A autora (2019).

FIGURA 5 - RELAÇÃO DA DEMANDA POR MACRO PONTO



FONTE: A autora (2019).

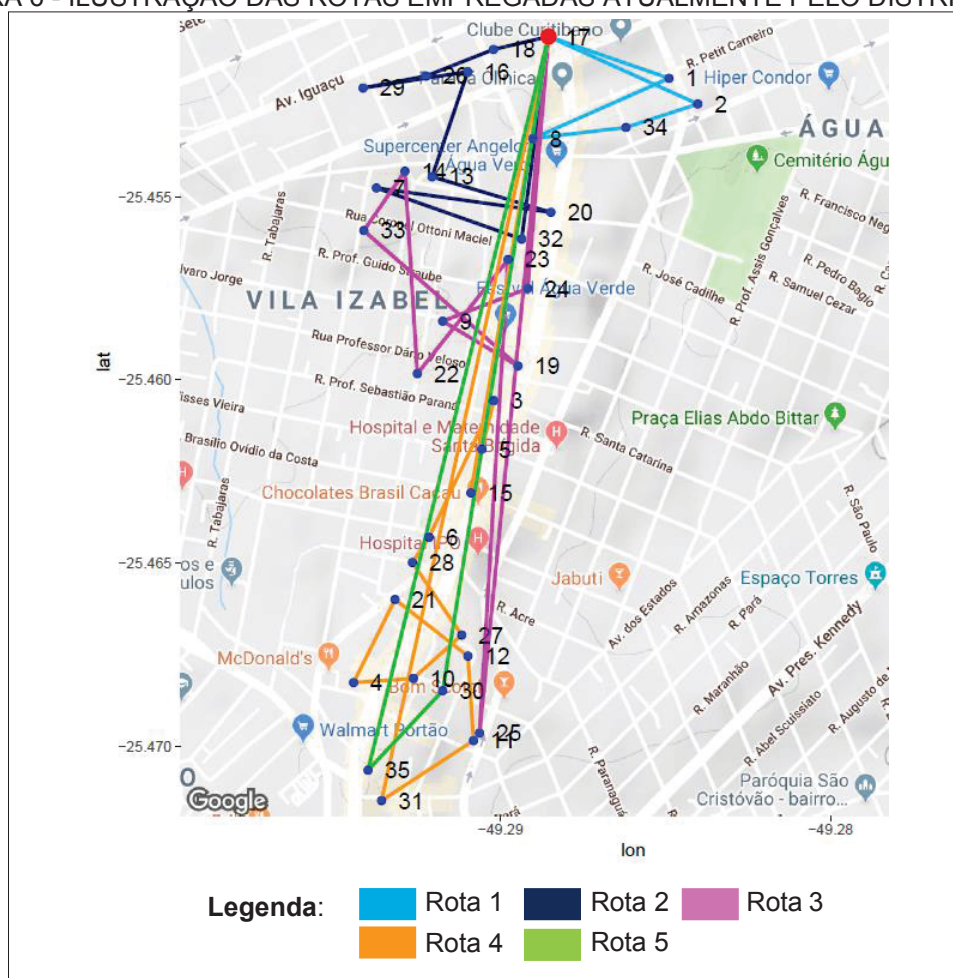
A situação atual das entregas que totaliza 36,2km está sintetizada na TABELA 2 e é ilustrada na FIGURA 6, onde as 5 rotas utilizadas atualmente são representadas. As rotas têm origem no ponto 17, que além de corresponder a um dos 35 macro pontos, representa o depósito onde os jornais são armazenados para a distribuição. Este ponto 17 corresponde, portanto, ao ponto onde as rotas têm início e para onde o entregador retorna para reabastecimento durante o processo das entregas, uma vez que a capacidade de carga da moto é de 100 exemplares por viagem.

TABELA 2 - ROTAS ATUALMENTE EMPREGADAS PARA ATENDIMENTO DO ROTEIRO 1010002

Roteiro	Sequência	Capacidade utilizada	Deslocamento (km)
Rota 1	0-17-1-8-34-2-0	101	5,3
Rota 2	0-18-26-29-16-13-20-7-32-0	103	6,85
Rota 3	0-24-9-19-33-14-22-23-25-0	97	9,8
Rota 4	0-15-5-3-6-28-27-10-4-21-12-11-31-0	108	13,46
Rota 5	0-30-35-0	70	7,2
TOTAL		479	42,61

FONTE: A autora (2019).

FIGURA 6 - ILUSTRAÇÃO DAS ROTAS EMPREGADAS ATUALMENTE PELO DISTRIBUIDOR



FONTE: A autora (2019).

Como pode-se observar, as cinco rotas estão “desbalanceadas” tanto em termos de utilização da capacidade, muitas vezes extrapolando a sua capacidade máxima de 100 unidades, quanto nas distâncias percorridas. Espera-se que com o processo de otimização aqui proposto, seja possível tornar as rotas mais equilibradas e com custo reduzido.

3 REVISÃO DE LITERATURA

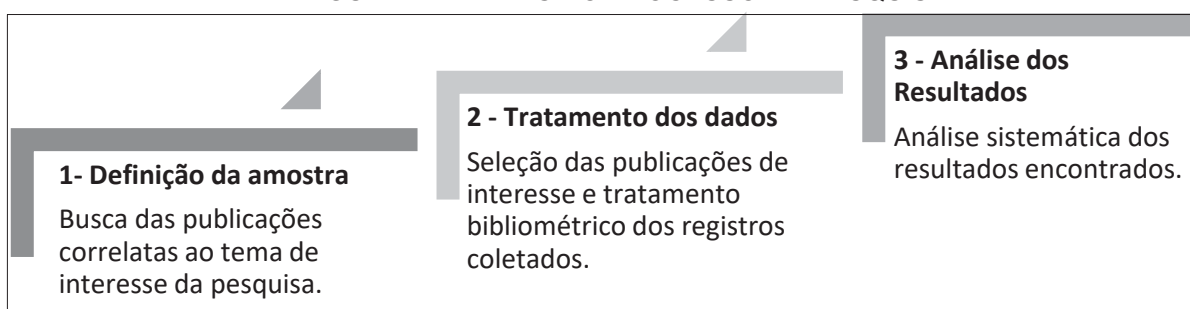
O presente capítulo da revisão da literatura está estruturado em três seções, iniciando pela realização da revisão bibliométrica e sistemática da literatura, seguido pela descrição de trabalhos correlatos levantados por meio da revisão bibliográfica realizada e, por fim, a fundamentação teórica de alguns conceitos necessários para compreensão desta pesquisa.

3.1 REVISÃO BIBLIOMÉTRICA E SISTEMÁTICA DA LITERATURA

O processo da revisão bibliográfica foi desenvolvido em três etapas principais, conforme descrito na FIGURA 7. Cada subseção apresentada em sequência nesta figura, corresponde ao detalhamento de uma das etapas.

A primeira etapa consistiu na definição da amostra inicial de artigos para embasamento do tema, seguida pela etapa de tratamento dos dados onde foi efetuada a seleção das publicações de acordo com os interesses desta pesquisa e por fim, foi realizada uma análise mais profunda dos documentos visando pela compreensão de seu conteúdo responder ao questionamento principal desta revisão: quais são as principais técnicas aplicadas nos últimos 10 anos para a resolução do PCV e/ou do PLF?

FIGURA 7 - ETAPAS DO PROCESSO DE PESQUISA



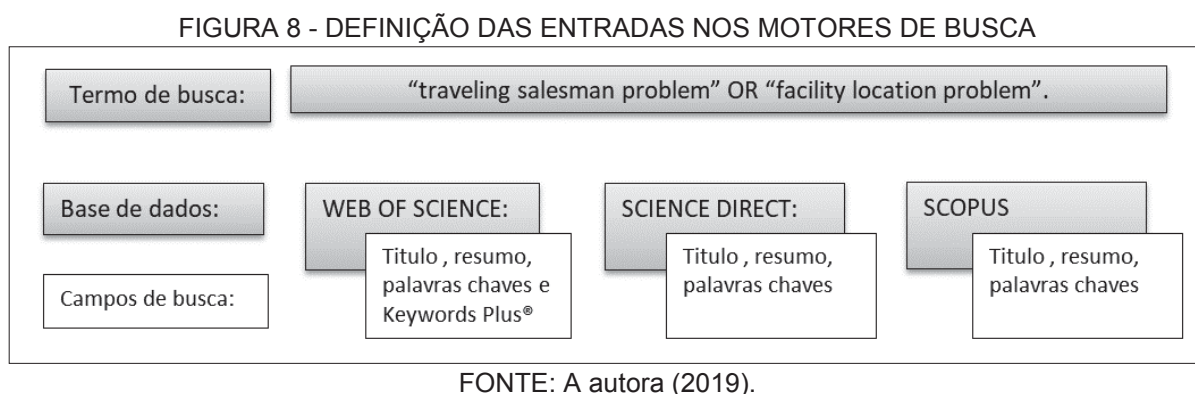
FONTE: A autora (2019).

3.1.1 Definição da amostra

Para a exploração inicial do tema, e consequente início dos trabalhos desta pesquisa, a busca dos artigos foi realizada com o objetivo de encontrar uma resposta

ao questionamento já mencionado: quais são as principais técnicas aplicadas durante os últimos 10 anos para a resolução do PCV e/ou do PLF?

Para isto, foram definidas as palavras chaves a serem utilizadas para busca nas bases de dados acadêmicas como: “*traveling salesman problem*” (TSP) or “*facility location problem*” (FLP). Para pesquisa optou-se por utilizar os termos em inglês, visto que a maior parte das publicações relevantes da área estão neste idioma. Como conector de pesquisa, utilizou-se o termo *OR* para que caso um trabalho trate exclusivamente de um dos dois temas seja mantido na base de artigos. Também, para início da busca, definiu-se as três bases de dados a serem consultadas: *Scopus*, *Science Direct* e *Web of Science*. A FIGURA 8 mostra os campos de busca consultados em cada uma das bases de dados.



A partir do procedimento iniciado conforme demonstrado na FIGURA 8, os demais passos para a composição do conjunto de artigos foram realizados conforme passos do fluxograma da FIGURA 9. O primeiro filtro empregado foi referente ao período de abrangência da busca, sendo consideradas apenas publicações do período de 2007 a 2018. Na base de dados *Web of Science* foram encontrados 4.911 resultados, na base de dados *Science Direct* 1.074 resultados e na base de dados *Scopus* 7.697 resultados.

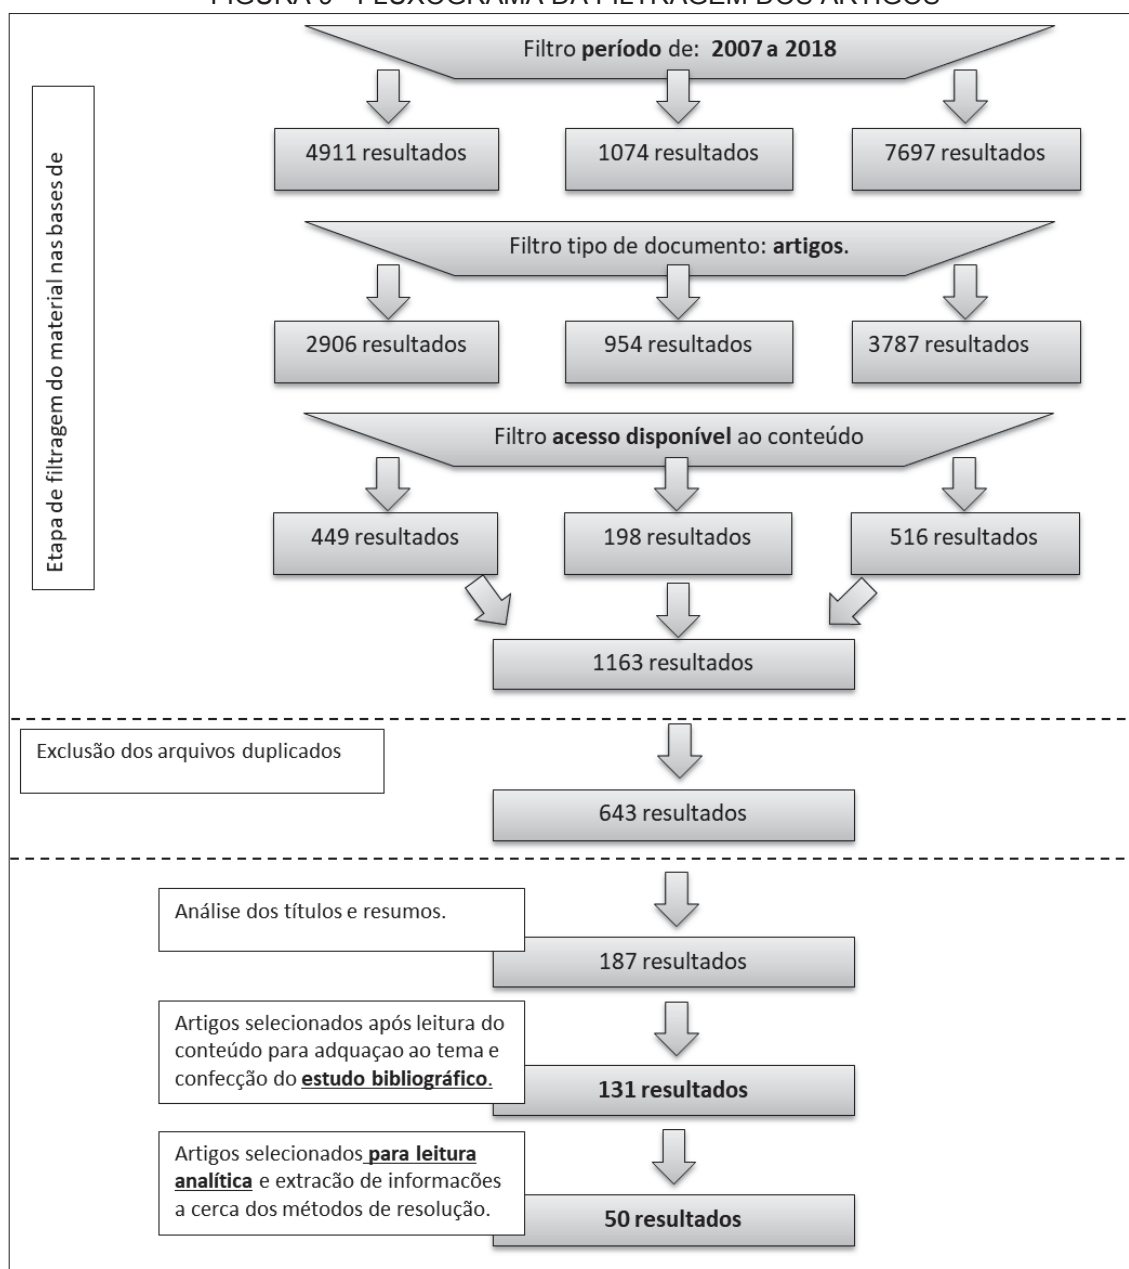
O próximo filtro empregado diz respeito ao tipo de documento. Foram considerados somente artigos publicados em revistas científicas e como pode-se ver no fluxograma da FIGURA 9, os resultados obtidos por base de dados foram reduzidos para 2.906 resultados na *Web os Science*, 954 resultados na *Science Direct* e 3.787 na base de dados *Scopus*. Neste passo da filtragem, o volume de artigos levantados estava em 7.647 (considerando-se a soma simples das três bases de dados).

Devido ao volume, optou-se por utilizar como “corte” a condicionante de que somente seriam considerados neste levantamento os artigos cujo conteúdo fosse disponibilizado na íntegra pela base de dados. Assim, o filtro de “documento acessível” foi adicionado nas três bases de dados. Resultando em uma soma simples de 1.163 documentos das três bases de dados. Os documentos das três bases, foram baixados na extensão de arquivos do tipo *BibTex* e carregados no *software* de gerenciamento de referências *Mendeley*, onde a etapa de exclusão de artigos repetidos foi realizada. Após a exclusão de arquivos idênticos levantados nas três bases, o volume de artigos ficou em 643.

O próximo passo foi a leitura dos títulos e resumos para que os documentos mantidos no conjunto de artigos fossem direcionados ao tema desta pesquisa. Neste momento os trabalhos que foram excluídos da base referem-se a trabalhos publicados em outros campos de pesquisa como biologia (cita-se alguns casos repetidos de trabalhos em relação a DNA), ótica e física, onde outras teorias que não matemáticas ou de otimização foram elencadas na resolução de TSP e/ou FLP, energias renováveis e outros casos onde apenas referenciava-se os termos buscados inicialmente. Assim, após esta primeira análise por títulos e resumos, chegou-se a uma quantidade de 187 publicações.

Como passo seguinte, foi realizada uma leitura um pouco mais aprofundada (incluindo metodologia e resultados) dos trabalhos selecionados na etapa anterior a fim de garantir que a amostra estivesse totalmente relacionada com o tema da pesquisa. Assim, neste passo mais alguns trabalhos foram excluídos da amostra, sendo que ressaltam-se como motivos para esta exclusão: trabalhos que continham melhorias em algoritmos sem sua completa explicação somente demonstrando testes realizados em TSP e/ou FLP; trabalhos focados em *Planning and Scheduling Problems*, *Inventory Routing Problems*, *Task Allocations* que continham apenas etapas ou menções ao TSP e/ou FLP; trabalhos demonstrando a complexidade da resolução de problemas TSP e/ou FLP; alguns casos de TSP 3D; artigos onde o foco era a introdução a linguagens de programação empregadas na resolução computacional dos problemas. Assim, 131 artigos foram selecionados para compor a base sobre a qual será efetuada a análise bibliométrica apresentada na seção 3.1.2.

FIGURA 9 - FLUXOGRAMA DA FILTRAGEM DOS ARTIGOS



FONTE: A autora (2019).

Por fim, estes 131 artigos selecionados foram classificados de acordo com o número de citações médias que receberam por ano. O número de citações foi levantado no *Google Scholar* levando-se em conta o fato de que os artigos são provindos de três bases diferentes. Assim, os artigos foram ordenados em uma tabela de relevância, por meio do resultado da divisão do número total de citações pelo tempo de circulação em anos. Optou-se por utilizar as citações médias por ano, para que um artigo mais novo, mesmo tendo sido citado várias vezes, não fosse excluído da base dos documentos para leitura analítica pela melhor posição de um mais antigo que tenha recebido mais citações.

Após a seleção do conjunto de artigos com 131 documentos foi possível realizar uma análise bibliométrica em relação à amostra. A análise bibliométrica foi dividida em 4 etapas a fim de obter-se informações relevantes sobre o conjunto de artigos: 1) análise da quantidade de citações dos documentos; 2) quantidade de trabalhos publicados por ano; 3) análise dos periódicos onde os artigos foram publicados; 4) levantamento das localidades onde as pesquisas foram desenvolvidas. Os resultados são mostrados na seção 3.1.2 Análise Bibliométrica.

A análise sistemática proposta como última etapa da revisão bibliográfica, foi realizada no conjunto de 50 artigos mais relevantes da amostra (em relação às citações médias recebidas por tempo de circulação) e teve como etapas realizadas: 5) uma análise dos *softwares* e linguagens de programação mais utilizados pelos autores; 6) análise do método utilizado para a resolução dos problemas. Os resultados são mostrados na seção 3.1.3 Análise Sistemática.

3.1.2 Análise Bibliométrica

Dentre os 131 artigos da base de dados, foi possível identificar os mais relevantes, considerando o número de citações médias por ano de circulação. Na TABELA 3 encontram-se os 10 artigos mais citados. O artigo com maior média de citações por ano é o trabalho de Deng et al. (2015) com o total de 89 citações. Caso apenas as quantidades de citações sejam levadas em consideração, o trabalho mais citado da base corresponde ao Hashimoto et al. (2008) com 153 citações.

TABELA 3 - ARTIGOS MAIS RELEVANTES CONSIDERANDO AS CITAÇÕES RECEBIDAS
(continua)

Autores	Título	Periódico	Citações Google Scholar	Citações Médias por ano
Deng et al. (2015)	<i>An Improved Genetic Algorithm with Initial Population Strategy for Symmetric TSP</i>	<i>Mathematical Problems in Engineering</i>	89	29,7
Mavrovouniotis et al. (2017)	<i>Ant Colony Optimization With Local Search for Dynamic Traveling Salesman Problems</i>	<i>IEEE Transactions on Cybernetics</i>	26	26,0
Tadei et al. (2017)	<i>The multi-path Traveling Salesman Problem with stochastic travel costs</i>	<i>Euro Journal on Transportation and Logistics</i>	21	21,0
Dong et al. (2017)	<i>Location of Facility Based on Simulated Annealing and ZKW" Algorithms"</i>	<i>Mathematical Problems in Engineering</i>	20	20,0


(conclusão)

Cacchiani et al. (2014)	<i>A set-covering based heuristic algorithm for the periodic vehicle routing problem</i>	<i>Discrete Applied Mathematics</i>	71	17,8
Zhan et al. (2016)	<i>List-Based Simulated Annealing Algorithm for Traveling Salesman Problem</i>	<i>Computational Intelligence and Neuroscience</i>	32	16,0
Hashimoto et al. (2008)	<i>An iterated local search algorithm for the time-dependent vehicle routing problem with time windows</i>	<i>Discrete Optimization</i>	153	15,3
Yang, J et al. (2008)	<i>Ant colony optimization method for generalized TSP problem</i>	<i>Progress in Natural Science</i>	150	15,0
Odili; Kahar (2016)	<i>Solving the Traveling Salesman's Problem Using the African Buffalo Optimization</i>	<i>Computational Intelligence and Neuroscience</i>	29	14,5
Majumdar; Bhunia (2011)	<i>Genetic algorithm for asymmetric traveling salesman problem with imprecise travel times</i>	<i>Journal of Computational and Applied Mathematics</i>	73	10,4

FONTE: A autora (2019).

Em relação à quantidade de trabalhos publicados por ano, foi possível elaborar o GRÁFICO 1 que mostra a tendência de aumento de publicações dos dois temas relevantes a esta pesquisa nos últimos anos. Apesar do FLP e o TSP serem problemas amplamente estudados, nos últimos anos tem-se um aumento na quantidade de trabalhos publicados na área, ressaltando-se um montante expressivo no ano de 2018 em relação aos demais. Cabe também relatar que na base de artigos não foi identificado algum trabalho publicado no ano de 2009.

GRÁFICO 1 - DISTRIBUIÇÃO AO LONGO OS ANOS DOS ARTIGOS LEVANTADOS




FONTE: A autora (2019).

Também foi realizada uma análise quanto aos periódicos onde os artigos foram publicados. No GRÁFICO 2, são apresentados os 10 periódicos onde se concentram o maior número de trabalhos. São apresentadas as quantidades de

artigos por periódico bem como seu H-index. Este índice foi consultado individualmente no site *Scimago Journal & Country Rank* (JCR).

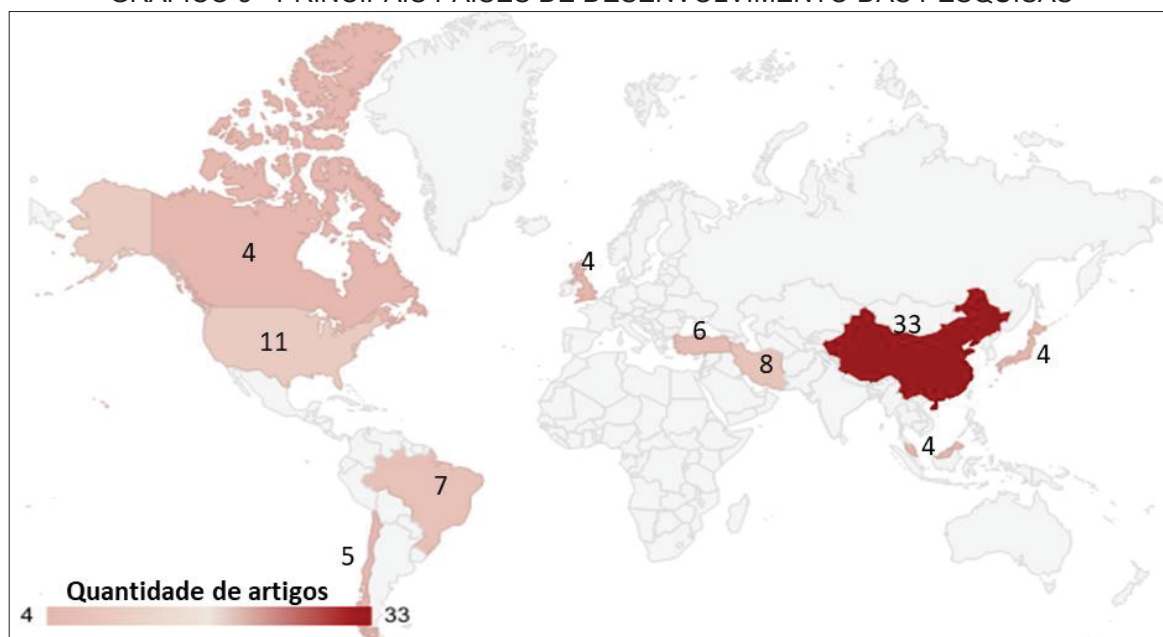
O JCR oferece uma perspectiva para avaliação e comparação de periódicos por meio da acumulação e tabulação de contagens de citações por meio do H-index. O H-index, definido por Hirsch (2005), é calculado pela relação do número de trabalhos publicados e suas citações, representa o número de artigos (h) que contêm uma quantidade de citações maior ou igual a h .



FONTE: A autora (2019).

Em relação à localização geográfica dos referidos centros de pesquisa, tem-se conforme apresentado no GRÁFICO 3 a concentração dos 10 países de maior número de publicações presentes na amostra, juntos estes 10 países correspondem a um total de mais de 60% dos artigos da amostra. Percebe-se um grande volume de trabalhos da China, em primeiro lugar da amostra totalizando 33 trabalhos, seguido dos Estados Unidos com 11, Irã com 8 e do Brasil com um total de 7 trabalhos.

GRÁFICO 3 - PRINCIPAIS PAÍSES DE DESENVOLVIMENTO DAS PESQUISAS



FONTE: A autora (2019).

3.1.3 Análise Sistemática

Em relação ao conteúdo dos artigos, para análise sistêmica, o conjunto de 131 artigos foi classificado e ordenado de acordo com a relevância. Para tanto, foi levantado por meio da plataforma *Google Scholar*, o número de citações de cada artigo e calculado o número médio de citações recebidas em relação ao tempo de circulação dos mesmos. Um conjunto de 50 artigos foi analisado de forma mais profunda para que fossem extraídas as informações a respeito do método de resolução e *software*/linguagem de programação empregado, conforme QUADRO 1.

QUADRO 1 - MÉTODOS DE RESOLUÇÃO EMPREGADOS NA AMOSTRA

(continua)

Autores / Ano	Título	Método de resolução	Software/ Language m
Deng et al. (2015)	<i>An Improved Genetic Algorithm with Initial Population Strategy for Symmetric TSP</i>	<i>K-means + AG</i>	MATLAB
Mavrovouniotis et al. (2017)	<i>Ant Colony Optimization With Local Search for Dynamic Traveling Salesman Problems</i>	ACO + LS	-
Tadei et al. (2017)	<i>The multi-path Traveling Salesman Problem with stochastic travel costs</i>	<i>Deterministic approximation / Simulação Monte Carlo</i>	C++
Dong et al. (2017)	<i>Location of Facility Based on Simulated Annealing and ZKW Algorithms</i>	SA + algoritmo de fluxo de custo mínimo	

(continuação)

Cacchiani et al. (2014)	<i>A set-covering based heuristic algorithm for the periodic vehicle routing problem</i>	ILP com relaxação pelo método de geração de colunas + ILS	CPLEX
Zhan et al. (2016)	<i>List-Based Simulated Annealing Algorithm for Traveling Salesman Problem</i>	SA melhorado por lista inicial de valores de temperatura	-
Hashimoto et al. (2008)	<i>An iterated local search algorithm for the time-dependent vehicle routing problem with time windows</i>	LS combinado com DP + VNS	-
Yang, J et al. (2008)	<i>Ant colony optimization method for generalized TSP problem</i>	ACO + LS (2-opt)	-
Odili; Kahar (2016)	<i>Solving the Traveling Salesman's Problem Using the African Buffalo Optimization</i>	<i>Swarm intelligence: African Buffalo Optimization</i>	MATLAB
Majumdar; Bhunia (2011)	<i>Genetic algorithm for asymmetric traveling salesman problem with imprecise travel times</i>	AG + intervalo avaliado da função de aptidão	C/C++
Jun-man; Yi (2012)	<i>Application of an Improved Ant Colony Optimization on Generalized Traveling Salesman Problem</i>	ACO melhorado por variação individual	-
El-Samak; Ashour (2015)	<i>Optimization of Traveling Salesman Problem using Affinity Propagation Clustering and Genetic Algorithm</i>	<i>Affinity propagation clustering + AG</i>	MATLAB
Pop et al. (2012)	<i>New mathematical models of the generalized vehicle routing problem and extensions</i>	ILP	-
Cheng; Mao (2007)	<i>A modified ant colony system for solving the travelling salesman problem with time windows</i>	ACO + duas heurísticas de busca local para as restrições temporais	-
Camacho-Vallejo et al. (2014)	<i>Solving the bilevel facility location problem under preferences by a stackelberg-evolutionary algorithm</i>	MIP + <i>Evolutionary algorithm</i>	CPLEX e C++
Yang, Jinhui et al. (2008)	<i>Solving traveling salesman problems using generalized chromosome genetic algorithm</i>	AG + nova estrutura de cromossomo	C++
Liao et al. (2012)	<i>Evolutionary algorithm to traveling salesman problems</i>	<i>Fuzzy C-Means clustering + PSO whit Genetic operators</i>	-
Ahmed (2014)	<i>The Ordered Clustered Travelling Salesman Problem: A Hybrid Genetic Algorithm</i>	AG Híbrido com crossover construtivo sequencial + LS (2-opt)	C++
Hussain et al. (2017)	<i>Genetic Algorithm for Traveling Salesman Problem with Modified Cycle Crossover Operator</i>	AG com operador de crossover modificado	MATLAB
Xu et al. (2018)	<i>Dynamic Vehicle Routing Problems with Enhanced Ant Colony Optimization</i>	K-means + ACO + LS (2-opt)	MATLAB
Bouman et al. (2018)	<i>Dynamic programming approaches for the traveling salesman problem with drone</i>	<i>Dynamic Programming</i>	Java
Da Silva; Urrutia (2010)	<i>A General VNS heuristic for the traveling salesman problem with time windows</i>	VNS + General VNS e LS (2-opt)	C++
Zhang (2007)	<i>A new approximation algorithm for the k-facility location problem</i>	<i>Neighborhood Search + LS</i>	-
Mestria et al. (2013)	<i>GRASP with path relinking for the symmetric Euclidean clustered traveling salesman problem</i>	GRASP + <i>path-relinking</i>	CPLEX
Contreras-Bolton; Parada (2015)	<i>Automatic Combination of Operators in a Genetic Algorithm to Solve the Traveling Salesman Problem</i>	AG com operadores obtidos por computação evolucionária	-

(continuação)

Pintea et al. (2013)	<i>The Generalized Traveling Salesman Problem solved with Ant Algorithms</i>	ACO Modificado	-
Kratka et al. (2014)	<i>A new mixed integer linear programming model for the multi level uncapacitated facility location problem</i>	MILP	CPLEX + Gurobi
Jafarzadeh et al. (2017)	<i>An Enhanced Genetic Algorithm for the Generalized Traveling Salesman Problem</i>	AG com NNS	-
Razali (2015)	<i>An Efficient Genetic Algorithm for Large Scale Vehicle Routing Problem Subject to Precedence Constraints</i>	AG + Correção da população inicial por grafos e classificação topológica	-
Karatas et al. (2016)	<i>A Comparison of p-median and Maximal Coverage Location Models with Q-coverage Requirement</i>	P-medianas e Maximal Covering Location Problems	CPLEX
Djenić et al. (2016)	<i>A variable neighbourhood search method for solving the long-term care facility location problem</i>	VNS + LS	C# + CPLEX
Mohsen (2016)	<i>Annealing Ant Colony Optimization with Mutation Operator for Solving TSP</i>	ACO Híbrido (ACO + SA mutation operator + LS)	Java
Cabrera G. et al. (2012)	<i>A hybrid approach using an Artificial Bee algorithm with mixed integer programming applied to a large-scale capacitated facility location problem</i>	Swarm intelligence: Artificial Bee Algorithm + MIP	Java + Gurobi
Sheu (2007)	<i>A hybrid fuzzy-optimization approach to customer grouping-based logistics distribution operations</i>	Fuzzy clustering + métodos de programação multi-objetivo.	LINGO
Aziz (2015)	<i>Ant Colony Hyper-heuristics for Travelling Salesman Problem</i>	ACO + LS (2-opt)	-
Iscan; Gunduz (2017)	<i>An application of fruit fly optimization algorithm for traveling salesman problem</i>	Swarm intelligence: Fruit Fly Optimization	-
Gabor; Van Ommeren (2010)	<i>A new approximation algorithm for the multilevel facility location problem</i>	ILP+ LP-relaxation	-
Qin et al. (2012)	<i>Combined simulated annealing algorithm for the discrete facility location problem</i>	SA	C#
Xiang et al. (2015)	<i>Solving Large-Scale TSP Using a Fast Wedging Insertion Partitioning Approach</i>	Particionamento, seguido de inserção.	MATLAB
Heilporn et al. (2010)	<i>The Delivery Man Problem with time windows</i>	MILP	CPLEX e C++
Hassanat et al. (2018)	<i>An Improved Genetic Algorithm with a New Initialization Mechanism Based on Regression Techniques</i>	AG com Pop. Inicial baseada em Regressão Linear	-
Gansterer et al. (2018)	<i>Exact solutions for the collaborative pickup and delivery problem</i>	Branch-and-cut + Benders Decomposition + geração de colunas	CPLEX
Wichapa e Khokhajaikiat (2018)	<i>Solving a multi-objective location routing problem for infectious waste disposal using hybrid goal programming and hybrid genetic algorithm</i>	Fuzzy Analytical Hierarchy Process + Goal Programming + AG + LS	-
Lagos et al. (2016)	<i>A Matheuristic Approach Combining Local Search and Mathematical Programming</i>	LS + Busca Tabu + MIP	Java + Gurobi.
Chowdhury et al. (2018)	<i>A Modified Ant Colony Algorithm for Traveling Salesman Problem</i>	ACO + LS (3opt)	MATLAB

(conclusão)

Sung; Jeong (2014)	<i>An Adaptive Evolutionary Algorithm for Traveling Salesman Problem with Precedence Constraints</i>	<i>Evolutionary Algorithm</i>	-
Yousefikhoshbakht et al. (2014)	<i>An Efficient Solution for the VRP by Using a Hybrid Elite Ant System</i>	ACO + LS	MATLAB
Buzna et al. (2014)	<i>An approximation algorithm for the facility location problem with lexicographic minimax objective</i>	ILP	C++
Byrka et al. (2016)	<i>Improved Approximation Algorithm for k-level Uncapacitated Facility Location Problem (with Penalties)</i>	LP + LP-relaxation	-


FONTE: A autora (2019).

LEGENDA: **ACO** (Ant Colony Optimization), **AG** (Algoritmo Genético), **DP** (Dynamic Programming), **GRASP** (Greedy Randomized Adaptive Search Procedures), **ILP** (Integer Linear Programming), **ILS** (Iterated Local Search), **LP** (Linear Programming), **LS** (Local Search), **MILP** (Mixed Integer Linear Programming), **MIP** (Mixed Integer Programming), **NNS** (Nearest Neighbor Search), **PSO** (Particle Swarm Optimization), **SA** (Simulated annealing), **VNS** (Variable Neighborhood Search).

Buscando agrupar os métodos de resolução, foi construído o GRÁFICO 4 que sintetiza a quantidade de vezes que cada algoritmo foi aplicado. A maioria dos autores recorre a métodos heurísticos para a resolução do TSP e do FLP. Há uma grande diversidade de heurísticas utilizadas, procedimentos exatos, assim como de combinações dos mesmos, a fim de melhorar a eficácia das soluções encontradas. Muitos trabalhos consistem em procedimentos sequenciais de construção de rotas seguidos por etapa de melhoria. Destacam-se como procedimentos mais utilizados a busca local, com 14 utilizações e o algoritmo genético em 11 trabalhos. Mais de 29 técnicas diferentes foram identificadas, ou seja, não há um consenso da melhor maneira para solucionar os TSP e FLP. Cada método apresenta suas características próprias e constitui uma maneira diferentemente eficaz de resolver os problemas.

Agrupando os métodos de resolução identificados nos trabalhos de uma maneira mais genérica, por meio de uma classificação em três categorias principais (1- Procedimentos Heurísticos, 2- Procedimentos Exatos e 3- Técnicas de agrupamento) é possível perceber pelo GRÁFICO 5 que os procedimentos heurísticos se destacam em relação ao emprego de procedimentos exatos de resolução para o TSP e FLP, o que pode ser justificado pela grande dificuldade computacional de resolução dos mesmos, principalmente em grandes instâncias.

GRÁFICO 4 - MÉTODOS DE RESOLUÇÃO IDENTIFICADOS NA AMOSTRA




FONTE: A autora (2019).

GRÁFICO 5 - TÉCNICAS DE RESOLUÇÃO AGRUPADAS POR CATEGORIAS



FONTE: A autora (2019).

Em relação aos *softwares*/linguagens de programação empregadas pelos autores, foi possível fazer um levantamento dos mais utilizados. Os resultados são mostrados no GRÁFICO 6 e percebe-se uma grande utilização da linguagem de programação C++ e da linguagem MATLAB, enquanto o solver CPLEX também se destaca.



FONTE: A autora (2019).

A fim de verificar as tendências dos autores em relação ao TSP e FLP, foi construída uma nuvem de palavras levando-se em consideração os títulos completos dos 50 artigos da amostra bem como suas palavras-chaves. Uma nuvem de palavras é uma forma de visualização gráfica de dados que demonstra a frequência com que as palavras aparecem em determinado contexto. Percebe-se, pela FIGURA 10 que além das duas palavras-chave desta pesquisa (*Traveling Salesman Problem* e *Facility Location Problem*) destacam-se algumas das heurísticas mais utilizadas como *Genetic Algorithm*, *Ant Colony Optimization*, o próprio termo '*heuristic*', e também *Vehicle Routing Problem*. De fato, o Problema de Roteamento de Veículos (*Vehicle Routing Problem*; VRP) está intimamente ligado com o interesse desta pesquisa, pois assim como o TSP é aplicado como um problema de otimização combinatória para fins de otimização da distribuição de mercadorias.

mais curto de uma fonte de alimento até o formigueiro sem usar pistas visuais. A trilha de feromônio deixada pela passagem das formigas é mais forte nos caminhos mais curtos, que são, portanto, na média, preferidos pelas formigas. Adicionalmente, para evitar o bloqueio do algoritmo em mínimos locais, um processo de mutação e uma técnica de busca local também são introduzidos como etapas adicionais da ACO proposta pelos autores. Os resultados mostram que quando o processo de mutação por busca local *2-opt* é usado, os resultados obtidos são melhores. Porém, os autores demonstram que os resultados são satisfatórios apenas quando a escala do problema é menor que 200 cidades.

Os autores Hashimoto et al. (2008) generalizam o PRV com Janelas de Tempo (PRVJT), permitindo que os tempos de viagem e os custos sejam funções dependentes do tempo e propõem um algoritmo de busca local para determinar as rotas dos veículos e então o subproblema de otimização em relação as janelas de tempo é resolvido por programação dinâmica. Para a exploração da vizinhança, os autores aplicam *2-opt*, *cross-exchange* e *Or-opt* com pequenas modificações. A operação *2-opt* remove duas arestas de duas rotas diferentes (uma de cada rota), dividindo assim cada rota em duas partes e faz a troca das segundas partes das duas rotas. A operação de *cross-exchange* remove dois caminhos de duas rotas (dois de cada rota) cujos comprimentos (isto é, o número de clientes no caminho) são no máximo L (parâmetro definido pelos autores), e os trocam. E por fim, a operação *Or-opt* explora as mudanças intra-rota, ou seja, remove um caminho de comprimento máximo C (parâmetro definido pelos autores) e insere-o em outra posição da mesma rota. Além disso, os autores propõem um método de filtragem que restringe a exploração da vizinhança, com base no fato de que existem muitas soluções sem perspectiva de melhoria. Os resultados computacionais em instâncias da literatura indicam que o algoritmo proposto é eficiente.

Ezzatneshan (2010) em seu trabalho propõe um ACO híbrido com um algoritmo exato para agrupamento dos clientes, considerando a ideia do problema de árvore geradora de custo mínimo, onde os nós que estão próximos um do outro provavelmente pertencerão ao mesmo ramo da árvore geradora mínima do gráfico e, portanto, provavelmente pertencerão à mesma rota no PRV. Em cada iteração do ACO, primeiro os autores aplicam uma versão modificada do algoritmo de Prim ao gráfico do problema para obter uma árvore de abrangência mínima. Dado um *cluster* de clientes, a solução é encontrar uma rota nesse *cluster* usando o ACO com uma

versão modificada da regra de transição das formigas. No final de cada iteração, a ACO tenta melhorar a qualidade das soluções usando um algoritmo de busca local e atualiza os pesos associados aos arcos do gráfico. A metodologia proposta pelos autores tem desempenho satisfatório, uma vez que os testes foram executados nas instâncias de Christofides, sendo que o desvio médio entre as soluções obtidas quando comparadas às melhores soluções não passam de 6,7%.

Majumdar e Bhunia (2011) tratam de uma versão do PCV Assimétrico, onde o tempo de viagem entre cada par de cidades é representado por um intervalo de valores (no qual se espera que o tempo real de viagem aconteça) em vez de um valor fixo (determinístico) como no clássico PCV Assimétrico. A resolução é feita por meio da proposição de um Algoritmo Genético (AG) modificado. Os testes efetuados pelos autores demonstram que os resultados da abordagem alternativa são satisfatórios quando comparados com os algoritmos genéticos tradicionais.

Os autores Jun-man e Yi (2012) também empregam o ACO na resolução do PCV, porém apresentam uma versão melhorada, chamada de procedimento IVRS (*Individual Variation and Routing Strategies*; Variação Individual e Estratégias de Roteamento). A primeira alteração, é que o algoritmo é projetado para reduzir os custos de processamento envolvidos com o roteamento das formigas no ACO. Nessa abordagem, somente a formiga que encontrar primeiro o caminho mais curto percorrerá todas as cidades, enquanto as outras irão parar quando esta formiga terminar de viajar. A segunda alteração, está na variação individual introduzida no ACO, que permite que as formigas tenham diferentes estratégias de rotas. Neste modelo, os autores dão maior relevância à estratégia de roteamento da formiga que funcionou melhor, isto é, aumentam o impacto do feromônio na rota dessa formiga. Como resultado, a qualidade das soluções do algoritmo ACO foi aprimorada. Os resultados dos testes computacionais demonstram que os resultados obtidos são sempre melhores ou iguais às soluções das instâncias da *Traveling Salesman Problem Library* (TSPLIB).

Qin et al. (2012) desenvolveram uma metodologia de *Simulated Annealing* (SA) Combinado para resolver o PLF. A metodologia baseada no SA é desenvolvida em duas etapas, a camada “interna” é responsável pela otimização da variável de decisão de localização da instalação, enquanto a camada “externa” determina a alocação de demanda sob a localização da instalação fixa, proveniente da camada interna. Dada uma solução inicial aleatória para cada um dos subalgoritmos, a mesma

é otimizada por meio do SA. Os resultados dos testes computacionais realizados em instâncias da OR-Library mostram que a metodologia proposta encontrou as soluções ótimas para todas as instâncias testadas, enquanto uma implementação em “etapa única” do SA apresentou um GAP médio de 15,9%.

No trabalho de Liao et al. (2012), os autores propõem uma estratégia em duas etapas para a resolução do PCV. Na primeira etapa, os pontos a serem visitados são agrupados em *clusters* por meio da técnica *Fuzzy C-Means*, onde uma rota é proposta para cada um dos n clusters criados e então as n rotas são mescladas em uma rota única. Esta abordagem gera primeiramente uma rota inicial sem cruzamento para que na segunda etapa, o PCV possa ser resolvido de forma mais eficiente pelo algoritmo de otimização de enxame de partículas (*Particle Swarm Optimization*; PSO) com operadores genéticos (*crossover* e mutação) proposto. Os testes foram executados em instâncias da TSPLIB com 14, 52, 130 e 1002 cidades, com e sem a etapa de *clusterização*. Os resultados mostram que o PSO com operadores genéticos adicionado da etapa de integração de clusters leva a uma melhor eficiência em lidar com o caso de grande número de cidades.

No trabalho de Korac et al. (2013), os autores propõem um AG melhorado para resolver o PLF *multi-level* e não levam em consideração as restrições de capacidade. A primeira melhoria é alcançada por meio de uma implementação mais eficiente da programação dinâmica, o que acelera o tempo de execução da metodologia geral do AG. O segundo aprimoramento é a junção do AG com o procedimento de busca local. A etapa de busca local é aplicada apenas no melhor indivíduo de cada população (desde que ele permaneça inalterado em 5 gerações consecutivas) iniciando a partir da 51ª geração. Caso o melhor indivíduo seja substituído por outro indivíduo de valor igual da função objetivo, mas código genético diferente, e permaneça inalterado durante 5 gerações, a busca local é aplicada novamente neste indivíduo. Os autores ressaltam que todas as ações durante a implementação objetivam um tempo computacional baixo. Os testes computacionais foram executados em instâncias de grande escala e os resultados obtidos são satisfatórios uma vez que o método é capaz de obter 5 soluções superiores aos melhores valores conhecidos e os tempos de execução são menores em comparação com a versão original do AG.

Xi et al. (2013) tratam do PLF de emergência, muito importante em termos da logística humanitária, uma vez que visam identificar os melhores lugares para

instalações de centros de armazenagem de recursos a serem utilizados em caso de um desastre, como equipamentos, tendas, cobertores, suprimentos, aquecedores e equipes. Os autores apresentam um estudo de caso no oeste da China, e propõem a resolução por meio do modelo das p -medianas modificado que minimiza a distância total e o número de instalações de emergência, sob uma restrição no tempo máximo necessário para acessar os pontos de demanda. Os autores propõem para resolução um VNS modificado, que inicia com um grande valor para o número das p instalações, permitindo que a cada iteração este valor decresça, e as respostas obtidas sejam iterativamente otimizadas. Os resultados obtidos para instâncias de teste da OR-Library equivalem às melhores soluções conhecidas em todos os casos testados, exceto uma instância onde o GAP foi de 0,02% demonstrando a eficácia do método proposto. Para o estudo de caso, o método também foi capaz de chegar à solução ótima quando comparado com a resolução do problema pelo *solver* CPLEX.

Cacchiani et al. (2014) solucionam um PRV periódico, que consiste em determinar um conjunto de rotas de custo mínimo para cada dia de um dado horizonte de planejamento, utilizando um algoritmo de otimização híbrido por Programação Linear Inteira Mista (PLIM), incorporando componentes heurísticos e exatos. O algoritmo é baseado em relaxação das restrições inteiras, sendo resolvido pelo método de geração de colunas, onde as colunas são geradas heurísticamente por um algoritmo de busca local iterado. O método da solução inteira aproveita a solução não inteira e aplica técnicas de fixação e liberação das colunas como uma busca local, usando uma lista tabu para evitar o ciclo. Os autores demonstram a eficácia da abordagem proposta por meio dos testes computacionais apresentados, uma vez que são capazes de incrementar as melhores soluções conhecidas para algumas instâncias.

Os autores Camacho-Vallejo et al. (2014) tratam do *bi-level* PLF, onde além do PFL abordam conjuntamente a otimização das preferências do cliente. Para isso, fazem uma reformulação do modelo de dois níveis, reduzindo-o a um problema de nível único misto que inclui o custo de abertura de novas instalações e os custos de distribuição, considerando as preferências dos clientes a serem atendidos por uma instalação específica. A abordagem dos autores consiste na junção dos conceitos do equilíbrio de Stackelberg para a teoria não-colaborativa de jogos com algoritmo evolucionário com principais etapas de população inicial, *crossover*, mutação e seleção. Os testes foram executados em instâncias da OR-Library com combinações

diferentes de tamanho entre clientes (50, 75, 100 e 1000) e locais para as facilidades (50, 75, 100, 300, 500) obtendo resultados satisfatórios uma vez que o erro médio em relação a melhor solução conhecida para as instâncias pequenas e médias ficou em torno de 0,6%, enquanto para as grandes instâncias ficou em torno de 5%. Adicionalmente, o baixo tempo computacional é observado para o procedimento com um tempo máximo de 2, 53 e 250 segundos para as instâncias pequenas, médias e grandes respectivamente.

Os autores Kratica et al. (2014) abordam o PLF de vários níveis sem capacidade. Uma variação do clássico PLF, onde cada cliente deve ser atendido, em geral, por uma sequência de, no máximo, k instalações diferentes (compondo assim os k -níveis). Os autores propõem uma nova formulação de PLIM para resolução do problema, sendo que para os testes utilizam os *solvers* CPLEX 12.4 e Gurobi 5.02 em instâncias da OR-Library. Os *solvers* CPLEX e Gurobi, por meio do uso do novo modelo de PLIM, são capazes de fornecer as soluções ótimas para todas as instâncias de pequeno e médio porte em um tempo relativamente curto. Adicionalmente, em comparação com outros 2 modelos de PLIM, os números de variáveis para instâncias de grande escala são significativamente reduzidos com o modelo proposto.

No trabalho de Deng et al. (2015) é apresentada uma nova estratégia para a geração da população inicial do AG por meio do uso do algoritmo *k-means* para a criação de n *clusters*, para posteriormente ser feita a resolução do PCV pelo AG, usado para obter o caminho ótimo local de cada grupo e, finalmente, um caminho ótimo global dos n grupos. Como a estratégia diminui o melhor valor de erro quando comparada ao método de população inicial aleatória (em 29,15%) e com o de população inicial gulosa (em 37,87%), mostra-se uma boa alternativa.

Zhan et al. (2016) apresentam um SA baseado em lista de temperatura de resfriamento, com coeficiente de resfriamento variável. O objetivo desta lista é a simplificação do ajuste de parâmetros do SA. Especificamente, a lista de temperaturas é criada primeiro e, em seguida, a temperatura máxima na lista é usada pelo critério de aceitação do algoritmo. A lista de temperaturas é adaptada iterativamente de acordo com a topologia do espaço de solução do problema. A eficácia e a sensibilidade dos parâmetros da lista de resfriamento são ilustradas por meio dos testes apresentados em instâncias do TSPLIB.

Odili e Kahar (2016) resolvem o PCV por meio da proposição de uma nova meta-heurística, Otimização do Búfalo-africano (ABO), uma técnica de otimização de

base populacional inspirada na migração de búfalos em busca de comida. Os búfalos africanos são capazes de aproveitar a inteligência coletiva do rebanho por meio do "voto", utilizando sons diferentes, utilizando o "waaa" os búfalos se comunicam para avançar e explorar locais mais seguros ou mais abundantes, e "maaa" que convoca os búfalos para permanecer e pastar em um local seguro e exuberante. Para a resolução do PCV, cada um dos n búfalos inicia aleatoriamente em uma cidade, então a cada iteração é calculado o valor do *fitness* para cada um, obtendo dois parâmetros, Bg : a localização dos melhores búfalos no rebanho e Bp : a melhor localização de cada búfalo. O algoritmo registra as coordenadas de cada búfalo, e juntamente com procedimentos heurísticos, constrói probabilisticamente uma rota adicionando as cidades a serem visitadas. Os resultados obtidos são satisfatórios quando comparados a outras heurísticas, porém os autores recomendam novos estudos para firmar a efetividade da nova heurística proposta.

No trabalho de Karatas et al. (2016), os autores fazem uma comparação entre dois modelos de localização de facilidades, o modelo das p -medianas e o problema de localização de cobertura máxima. O problema das p -medianas visa encontrar as localizações das p instalações entre os locais candidatos, de modo que a distância total ponderada entre todos os pontos de demanda e suas respectivas instalações seja minimizada. Já o problema de localização de cobertura máxima procura maximizar o número total de demandas atendidas com um determinado número de instalações e orçamento definido. Adicionalmente, os autores consideram como variante o critério de Q-Cobertura com atribuições de instalações primárias e de *backup*. Nos casos em que é necessária uma cobertura múltipla ($Q > 1$), as instalações restantes que cobrem (ou às quais são atribuídas) uma demanda, são nomeadas como as facilidades de *backup*. Os autores criaram instâncias de teste onde localizações candidatas às instalações e de demanda foram uniformemente e aleatoriamente distribuídas dentro de uma região quadrada de 100 km x 100 km. Os resultados computacionais de ambos os modelos para diferentes valores de Q (parâmetro Q-Cobertura, $Q = \{1,2,3\}$), foram avaliados basicamente pelas distâncias médias para coberturas primárias e/ou de *backup*. Em geral, o modelo das p -medianas superou o modelo de localização de cobertura máxima em quatro critérios de cinco.

Djenić et al. (2016) trabalham com uma versão modificada do PLF, abordando o problema de determinar locais para instalar centros de saúde de longo prazo com o

objetivo de alocar os pacientes aos centros mais próximos e também minimizar o número máximo de pacientes que são atribuídos a uma única instalação, equilibrando assim a carga de trabalho em cada centro médico. Para resolução os autores utilizam uma meta-heurística baseada na técnica *Variable Neighbour Search* (VNS) para resolver instâncias grandes envolvendo até 400 locais de instalação em potencial. Uma solução inicial viável é gerada por uma versão reduzida da técnica VNS. A principal vantagem do método VNS proposto é uma variante do *Fast Interchange Method* que utiliza uma estrutura de dados complexa quando comparada a ideias similares da literatura, mas os resultados computacionais mostram que a estratégia aplicada produziu reduções significativas no tempo de execução, e melhor qualidade da solução comparada aos resultados obtidos pela implementação simples do VNS.

Os autores Lagos et al. (2016) criam um procedimento *matheurístico* para resolução do PLF capacitado que combina Busca Local (integrada com os conceitos da Busca Tabu; BT) e PLIM, focados em resolver grandes instâncias. Uma solução inicial de melhor qualidade é obtida por meio do *solver* GUROBI, resolvendo parcialmente o subproblema de quais instalações devem ser “abertas”. Em um tempo de 15s, a solução obtida pelo *solver* é mantida como solução inicial para a Busca Local, mesmo que a resposta ainda não seja a ótima, os autores demonstram pelos testes computacionais que o procedimento obtém melhores resultados do que a solução inicial aleatória para a busca local, uma vez que o GAP médio, em relação ao melhor valor conhecido das instâncias testadas, do procedimento proposto é de 0,05% em relação a um GAP médio de 10% para solução inicial aleatória.

Mavrovouniotis et al. (2017) abordam uma extensão do PCV, mais especificamente, o PCV Dinâmico, onde as distâncias (ou tempos de viagem) entre duas cidades estão sujeitos a alterações. A solução é obtida pela aplicação de uma versão memética do algoritmo ACO com a integração de um operador de busca local. A melhor solução encontrada pela ACO é passada para o operador de busca local, que remove e insere cidades a fim de melhorar a qualidade da solução. A etapa de busca local é realizada antes do procedimento de atualização do feromônio. Os resultados obtidos em instâncias adaptadas da TSPLIB por meio de uma variável aleatória uniformemente distribuída, demonstram que o método mantém um bom equilíbrio entre o tempo computacional e a qualidade da solução aproximada obtida mesmo perante as mudanças dinâmicas assimétricas dos pesos entre os nós (cidades).

Dong et al. (2017) propõem um método para o PLF por meio da combinação da meta-heurística SA, uma técnica de busca local probabilística e do algoritmo ZKW (um algoritmo de fluxo de custo mínimo). O método proposto pelos autores é aplicado a um caso real, com o objetivo de implantar o servidor de conteúdo de vídeo nos nós apropriados em um grafo não direcionado para satisfazer os requisitos dos nós de consumo com o menor custo. Ao mesmo tempo, o nó pode transmitir dados pelo *link* de rede para os outros nós que estão conectados. O *link* de rede cobra uma taxa de aluguel com base no uso da largura de banda. Os resultados, quando comparados aos obtidos pela BT, mostram que o novo método é mais adequado para uma escala intermediária de problemas, uma vez que os dois diferem nas estratégias de escapar de ótimos locais. A BT tentará escapar quando estiver presa no ótimo local, enquanto o recozimento simulado poderá escapar a qualquer momento, de acordo com a probabilidade de aceitação de novas soluções piores.

Tadei et. al (2017) tratam do PCV Multi-Caminhos com Custos de Viagem Estocásticos (tempos de deslocamento estocásticos), onde cada par de nós é conectado por vários diferentes caminhos e cada caminho tem um custo de viagem estocástico com distribuição de probabilidade desconhecida. Os autores fazem uma aproximação determinística destes tempos para possibilitar a resolução. A solução obtida a partir de dados empíricos de uma cidade de porte médio, quando comparada à obtida pela simulação de Monte Carlo, mostra tanto a precisão quanto a eficiência da aproximação determinística, com um *gap* percentual médio em torno de 2% e uma redução dos tempos computacionais de duas ordens de grandeza.

Xu et al. (2018) tratam do PRV dinâmico, uma grande e importante variante do PRV, mais próximo da cena logística real. No PRV dinâmico, as demandas dos clientes aparecem com o tempo, e os pontos dos clientes não-atendidos precisam ser atualizados e reorganizados durante a execução da programação dos caminhos. Para a resolução, os autores propõem uma ACO combinada com a operação de *cluster* pelo método *k-means* e etapa de *crossover*. Primeiramente, o conjunto de clientes é dividido em *clusters* pelo algoritmo *k-means* e como próxima etapa tem-se a construção de rotas onde a estratégia de seleção do próximo cliente a visitar depende de uma regra probabilística, que leva em consideração a visibilidade das formigas e o feromônio em formação. Após, tem-se a aplicação de dois operadores genéticos de *crossover* diferentes a fim de aumentar a diversidade das soluções obtidas. Por fim, os autores executam uma etapa de busca local (*2-opt*) e somente então ocorre a etapa

de atualização do feromônio da ACO. O processo é repetido iterativamente até que a condição de parada seja satisfeita. Os resultados dos testes mostram que a metodologia proposta é capaz de obter o melhor valor em comparação a outras heurísticas como BT, VNS e AG em apenas 40 iterações.

Os autores Hassanat et al. (2018) fazem um estudo do impacto no resultado final, gerado pela estratégia de geração da população inicial empregada no AG durante a resolução do PCV. Os autores também propõem uma nova metodologia para agrupamento dos pontos de demanda dos clientes baseada em regressão linear, objetivando separar os pontos pelo emprego de linhas de regressão e suas correspondentes linhas perpendiculares. Assim, dentro de cada grupo, sub-rotas são criadas e depois conectadas formando uma solução única, que é a semente da população inicial, a partir da qual, pelo operador de mutação novas soluções são criadas. Após, com as etapas seguintes do AG (seleção, *crossover*, mutação), o método busca otimizar as soluções. Os resultados computacionais mostram que a taxa de erro média da técnica proposta se mantém mínima quando comparada a outras técnicas como vizinho mais próximo (*Nearest Neighbor*; NN), com taxa de erro média de 9,2% e agrupamento aleatório, com taxa de erro média de 18,6%.

Os autores Fuentes et al. (2018) utilizam a meta-heurística de busca local com *Multi-Restart* para resolução do PCV, porém a fim de facilitar a obtenção de soluções iniciais factíveis, os autores primeiramente aplicam a técnica de *clusterização k-means*. Em seguida, uma heurística construtiva baseada em uma lista de distâncias entre todos os pontos de cada *cluster*, com distâncias em ordem crescente, é criada. Uma rota para cada *cluster* é construída obedecendo essa sequência de distâncias mínimas e a etapa de busca local com *Multi-Restart* é realizada, a fim de melhorar a rota obtida no passo anterior. As rotas individuais de cada *cluster* são agrupadas obedecendo-se a regra de menor distância entre os seus respectivos centroides para o sequenciamento da rota única. Os experimentos computacionais foram realizados em 10 diferentes instâncias da TSPLIB com a intenção de comparar o desempenho do método proposto em relação ao AG. O método proposto tem melhores resultados do que o AG em relação aos intervalos de confiança de custo e tempo computacional.

Com base em um estudo de caso, 107 hospitais e 6 municípios candidatos no Nordeste da Tailândia, os autores Wichapa e Khokhajaikiat (2018), abordam o problema de roteamento e de localização para eliminação de resíduos infecciosos, e destacam que consiste em um processo difícil e complexo, pelo fato de necessitar da

combinação de fatores intangíveis e tangíveis e depender de vários regulamentos. Os autores consideraram critérios como infraestrutura, geologia e critérios socioambientais, avaliando pesos prioritários globais utilizando o processo de hierarquia analítica difusa (*Fuzzy AHP*) para definição dos mais relevantes. Depois disso, um novo modelo de problema de localização de instalações multi-objetivo, visando minimizar o custo total e maximizar o peso total da localização sob as restrições existentes, foi elaborado e resolvido com a integração da técnica *Fuzzy AHP* com Programação por Objetivos (ou *Goal Programming*; GP). Finalmente após os locais das instalações para os resíduos estarem definidos, o PRV para o estudo de caso foi formulado e resolvido por um AG que hibridiza a heurística de inserção *push forward* e etapa de busca local (*2-opt*, *insertion-move* e *interexchange-move*). Os resultados computacionais foram obtidos para a heurística proposta e comparados aos do *software* LINGO (*Language for Interactive Optimizer Systems*) onde é possível perceber a eficácia da heurística proposta para o PRV uma vez que obteve os mesmos resultados que as respostas exatas providas do LINGO.

Um estudo de caso para determinar a localização ótima de aeronaves para atividades de transporte de órgãos humanos é apresentado pelos autores Cacchiani et al. (2018). Os autores propõem um modelo de PLIM para determinar a distribuição ótima de aeronaves em um dado conjunto de *hubs* e sob a demanda extraída do banco de dados de transplantes italiano, consistindo em uma aplicação do PLF não-capacitado, onde as aeronaves são instalações a serem localizadas e as solicitações de transporte de órgãos representam a demanda. O modelo proposto objetiva minimizar a distância total percorrida bem como o número necessário de aviões. O modelo foi resolvido com o *solver* CPLEX em dois cenários propostos com, respectivamente, dois e três *hubs*. Como resultado, as solicitações de transporte podem ser cobertas com seis aeronaves, quantidade considerada suficiente para lidar com as tendências crescentes dos números das atividades de transplante emitidas. Ambos os cenários otimizados permitiriam na prática uma redução no uso de recursos, uma vez que os autores mencionam que no cenário atual da administração um número maior de aeronaves está operando.

Os autores Hu et al. (2018) também fazem um estudo de caso para a construção de um sistema de logística subterrânea na China, integrado com o transporte terrestre (superfície) para transporte de bens. A abordagem é feita por meio de um PLF (centros de despacho, estações de transferência, pontos de coleta) e de

um PRV, que visa determinar as localizações ótimas dos pontos enquanto simultaneamente determina as melhores rotas. Os autores formulam um problema de localização-roteamento com função objetivo visando minimizar o custo total, que inclui o custo de construção do nó, o custo de construção da linha de transporte subterrânea, o custo de transporte na superfície e o custo de transferência. Como os roteiros são influenciados pelos volumes das cargas devido às restrições dos dutos subterrâneos, os autores propõem um método de seleção de roteamento dinâmico e empregam uma abordagem heurística para resolução, um AG com operação de migração. Como resposta os autores obtêm os dados de toda a rede logística, superfície e subterrânea, indicando onde cada nó deve ser localizado e de qual tipo o mesmo deve ser.

Hoekstra e Phillipson (2018) propõem duas abordagens heurísticas para resolver o PLF Capacitado para Multi-Serviço, aplicado ao planejamento da rede de acesso de uma cidade inteligente, para oferecer múltiplos serviços aos habitantes da cidade. O objetivo é encontrar uma distribuição viável e eficiente dos serviços em uma área urbana, de modo que os custos totais, sendo os de abertura fixa e custos fixos de serviço, sejam minimizados sem violar as restrições de capacidade, satisfazendo todos os requisitos de demanda. Esse problema abrange a atribuição de equipamentos aos pontos de acesso, responsáveis pela oferta dos serviços ao cliente e atendimento de sua demanda. A primeira heurística proposta, denominada heurística de Resolução Sequencial, considera que a cada etapa apenas um dos serviços é avaliado, e a atribuição de localização desse serviço é otimizada, por fim as soluções das várias etapas são combinadas para se obter a atribuição de localização global. A segunda abordagem, estende a heurística de Resolução Sequencial, atualizando alguns parâmetros de custo entre as várias etapas de otimização. Por causa das atualizações de custos intermediários, as etapas não são mais independentes, o que implica que a ordem em que os vários serviços são considerados afeta a qualidade da solução geral. No total, nove instâncias de teste são consideradas, correspondendo a pequenas subáreas da cidade de Amsterdam. Para a abordagem exata, o *solver* CPLEX é usado para resolver o problema de PLIM e a linguagem de programação MATLAB é usada para as heurísticas. Os resultados para os três cenários (heurística 1, heurística 2 e exata) mostram que há uma grande diferença de custo entre a heurística 1 e o método exato para todas as instâncias, que excedem em média 24,0% a solução exata, e boa qualidade de solução da heurística 2, que excedem em média apenas 3,6% à solução exata. Como o tempo de

processamento do *solver* aumenta com o tamanho do problema as abordagens heurísticas são de grande importância em casos onde o tempo de processamento é curto.

No trabalho de Gan et al. (2018), os autores apresentam um estudo de caso da cidade de Shenzhen na China para localização de Instalações de Facilidades de logística urbana com consideração de emissões de Gases de Efeito Estufa (GEE). O objetivo é a formulação de um modelo ecológico de localização de instalações para minimizar tanto o custo total da construção e da operação da rede logística urbana quanto às emissões de gases de efeito estufa proveniente do deslocamento dos caminhões. Com base em relações matemáticas das taxas de emissões de GEE e em vários fatores macroscópicos, obtidos por análise de regressão multivariada em um grande conjunto de dados empíricos de caminhões, os autores obtêm a função de estimativa de taxas de emissão. O PLF é então modelado pela integração do modelo de localização de facilidades clássico e da função de emissões de GEE. Para resolução, os autores empregam o algoritmo PSO aplicado a dados reais coletados na cidade de Shenzhen no ano de 2011. Após a otimização, as instalações totais da cidade diminuem de 29 a 25. O número de viagens de caminhão da cidade também diminui de 90269 para 68117. Os autores ressaltam que é possível reduzir as emissões de GEE, evitando viagens desnecessárias, possibilitando uma gestão logística ecologicamente correta e mais significativa do que apenas adicionando números de facilidades.

Visando agrupar as principais ideias dos trabalhos correlatos apresentados, o QUADRO 2 aborda os pontos chaves de cada um resumidamente. São apresentados os autores e ano de cada uma das publicações, o objetivo de cada um dos trabalhos e em seguida as técnicas utilizadas para resolução do PLF e ou do PCV. Quando a resolução do PLF ou do PCV não foi realizada de maneira “separada” pelos autores, indica-se com o termo “Não abordado”.

QUADRO 2 - RESUMO DAS PUBLICAÇÕES RELACIONADAS AO TEMA DA PESQUISA
(continua)

Autores / Ano	Objetivo	Técnicas utilizadas no PLF	Técnicas utilizadas no PCV
Zhang (2007)	Determinar a localização ótima para instalação de k – facilidades de modo a minimizar o custo total de abertura das instalações e serviços aos clientes.	Busca Local	Não abordado

(continuação)

Yang et al. (2008)	Dado o conjunto inicial de clientes já agrupado em <i>clusters</i> , encontrar a rota de custo mínimo passando exatamente por um único nó de cada <i>cluster</i> .	Não abordado;	ACO; Busca local
Hashimoto et al. (2008)	Determinar as m rotas de menor custo para entregas em instâncias de 100 clientes respeitando as restrições temporais (abertura e fechamento das janelas de atendimento de cada cliente).	Não abordado;	Busca local; Programação dinâmica
Ezzatneshan (2010)	Determinar m rotas de custo mínimo para um conjunto de n clientes satisfazendo restrições de capacidade e demanda.	Algoritmo de Prim	ACO
Majumdar; Bhunia (2011)	Determinar a rota de menor custo (tempo mínimo) para visita de todos os nós em instâncias de 10, 15, 20 e 30 clientes.	Não abordado	AG
Jun-man; Yi (2012)	Dado o conjunto inicial de clientes já agrupado em <i>clusters</i> , encontrar a rota de custo mínimo passando exatamente por um único nó de cada <i>cluster</i> .	Não abordado	ACO
Qin et al. (2012)	Determinar o número e a localização das instalações e alocar os clientes as mesmas, de forma que o custo total seja minimizado.	SA	Não abordado
Liao et al. (2012)	Determinar a rota de menor custo para visita de todos os nós em instâncias de 14, 52, 130 e 1002 clientes.	<i>Fuzzy C-Means</i>	PSO; Operadores genéticos
Korac et al. (2013)	Dados um conjunto de clientes, com determinada demanda, um conjunto de possíveis instalações particionadas em k níveis, determinar quais instalações abrir simultaneamente em cada nível e atribuir os clientes a uma sequência de instalações abertas, de forma a minimizar o custo total.	AG; Busca Local	Não abordado
Xi et al. (2013)	Identificar os melhores lugares para instalações de centros de armazenagem de recursos a serem utilizados em caso de um desastre, minimizando o custo de instalação.	VNS	Não abordado
Cacchiani et al. (2014)	Determinar um conjunto de rotas de custo mínimo, para cada dia de um dado horizonte de planejamento, para atendimento da demanda de n clientes.	Não abordado	PLIM
Camacho-Vallejo et al. (2014)	Determinar a localização ótima para as instalações, minimizando o custo total considerando as preferências dos clientes.	Teoria dos Jogos; Algoritmo evolucionário	Não abordado
Kratka et al. (2014)	Determinar a localização ótima para instalação de facilidades para minimizar o custo total de abertura das instalações e serviços aos clientes. Cada cliente deve ser atendido, por uma sequência de, no máximo k instalações (compondo assim os k -níveis).	PLIM	Não abordado
Deng et al. (2015)	Determinar a rota de menor custo para visita de todos os nós (clientes).	<i>k-means</i>	AG
Zhan et al. (2016)	Determinar a rota de menor custo para visita de todos os clientes.	Não abordado	SA
Odili; Kahar (2016)	Determinar a rota de menor custo para visita de todos os clientes.	Não abordado	ABO
Karatas et al. (2016)	Dado um número requerido de instalações a abrir, determinar a localização das instalações e alocar os clientes as mesmas, de forma que o custo total seja minimizado.	P -medianas; Problema de localização de cobertura máxima	Não abordado

(conclusão)

Djenić et al. (2016)	Determinar locais para instalar centros de saúde de longo prazo com o objetivo de alocar os pacientes aos centros mais próximos e também minimizar o número máximo de pacientes que são atribuídos a uma única instalação.	VNS	Não abordado
Lagos et al. (2016)	Determinar a melhor localização para construção de depósitos para distribuição de mercadorias e alocar os clientes aos mesmos de forma que o custo total seja minimizado.	PLIM; Busca local	Não abordado
Mavrovounioti et al. (2017)	Determinar a rota de menor custo para visita de todos os clientes, dado que as distâncias (ou tempos de viagem) entre duas cidades estão sujeitos a alterações dinâmicas.	Não abordado	ACO; Busca Local;
Dong et al. (2017)	Determinar as melhores localizações para implantação dos servidores de conteúdo de vídeo para satisfazer os requisitos dos nós de consumo com o menor custo.	SA; Algoritmo de Fluxo de Custo mínimo	Não abordado
Dong et al. (2017)	Determinar a rota de menor custo para visita de todos os clientes, dado que cada par de nós é conectado por vários diferentes caminhos e cada caminho têm um custo de viagem estocástico com distribuição de probabilidade desconhecida.	Não abordado	Aproximação determinística; PLIM
Xu et al. (2018)	Determinar a rota de menor custo para visita de todos os clientes, dado que as demandas dos clientes aparecem com o tempo e clientes não-atendidos precisam ser atualizados e reorganizados durante a execução da programação das rotas.	<i>k-means</i>	ACO; Operadores genéticos; Busca local
Hassanat et al. (2018)	Determinar a rota de menor custo para visita de todos os clientes.	Regressão linear	AG
Fuentes et al. (2018)	Determinar a rota de menor custo para visita de todos os clientes.	<i>k-means</i>	Heurística construtiva; Busca Local
Wichapa e Khokhajaikiat (2018)	Determinar a localização ótima para instalação de centros de eliminação de resíduos infecciosos e determinar as rotas de custo mínimo para transporte dos mesmos.	Fuzzy AHP; Goal Programming (GP)	AG; Busca Local;
Cacchiani et al. (2018)	Determinar a localização ótima de aeronaves para atividades de transporte de órgãos humanos.	PLIM	Não abordado
Hu et al. (2018)	Determinar a localização ótima para construção de diferentes tipos de facilidades em um sistema de logística subterrânea integrado com o transporte terrestre (superfície) para transporte de bens.	AG	AG
Hoekstra, G. e Phillipson (2018)	Determinar a localização ótima para instalação de equipamentos ("box services") que correspondem a pontos de acesso para clientes em uma rede distribuição de serviços múltiplos no contexto de uma <i>smart-city</i> .	Heurística Construtiva; PLIM	Não abordado
Gan et al. (2018)	Determinar a localização para instalação de depósitos para logística urbana levando em consideração a minimização de custos e das emissões de GEE.	PSO	PSO

FONTE: A autora (2019).

Por meio dos trabalhos identificados na amostra obtida pela revisão sistemática da literatura, é possível perceber que a maioria dos métodos de resolução

empregados não fornece a solução exata. Isto porque os problemas PCV e PLF são classificados como NP-*hard*, são problemas de difícil solução, cujo grau de dificuldade em resolvê-lo aumenta exponencialmente conforme o tamanho do problema. Nestas circunstâncias, a solução mais barata (em termos computacionais e de tempo) é o uso de algoritmos heurísticos e/ou meta-heurísticos. Dentre os trabalhos correlatos nesta seção, pode-se verificar que houve diversas publicações onde essas técnicas são empregadas.

3.3 FUNDAMENTAÇÃO TEÓRICA

Nesta seção são apresentados os conceitos e embasamento importantes para esta pesquisa, relacionados ao PLF e ao PCV, bem como técnicas de resolução exatas, heurísticas e meta-heurísticas para os mesmos.

3.3.1 Pesquisa Operacional e Otimização Combinatória

A Pesquisa Operacional (PO) utiliza métodos científicos para analisar sistemas complexos e auxiliar no processo de tomada de decisão. Trata da resolução de uma série de problemas de otimização por meio do emprego de diferentes técnicas. Os modelos de PO são estruturados de maneira lógica e formal, com o objetivo de otimizar o funcionamento dos sistemas representados (GOLDBARG et al., 2016).

A otimização é o processo de encontrar a melhor solução (ou solução ótima) para um problema. Assim, na resolução de problemas de otimização combinatória objetiva-se encontrar a melhor combinação dentre um conjunto de variáveis para maximizar ou minimizar uma função, geralmente chamada de função objetivo ou função custo. Os problemas de otimização podem ser divididos em três categorias: aqueles cujas variáveis assumem valores reais (ou contínuos), aqueles cujas variáveis assumem valores discretos (ou inteiros) e aqueles em que há variáveis inteiras e contínuas, classificados, respectivamente, como problemas de Otimização Contínua, Otimização Combinatória ou Discreta, e Otimização Mista (BELFIORE; FÁVERO, 2013).

Os métodos de resolução de problemas de otimização combinatória podem ser divididos em duas grandes classes, em métodos exatos e métodos heurísticos. Métodos exatos, são aqueles que fazem uso de técnicas de programação matemática

e algoritmos como *branch and bound* para encontrar a solução ótima de um problema enquanto algoritmos heurísticos são procedimentos que usam a estrutura do problema de uma maneira matemática (e geralmente intuitiva) para fornecer soluções viáveis ou quase ótimas. Uma heurística é considerada efetiva se as soluções estiverem consistentemente próximas da solução ótima.

O PLF, o PCV e técnicas de resolução dos mesmos, temas centrais desta presente pesquisa e estudados pela PO, são descritos com mais detalhes nas próximas seções.

3.3.2 Problema de Localização de Facilidades – PLF

A determinação da localização de facilidades tem sido amplamente estudada nos últimos anos devido seu grande impacto tanto no setor público quanto no setor privado, pois este problema busca a solução mais vantajosa para definir onde devem ser instalados armazéns, centros de distribuição, escolas, portos, aeroportos entre os mais diversos tipos de instalações, de maneira a selecionar os locais ótimos dentre um conjunto de locais candidatos (BELFIORE; FÁVERO, 2013; ARENALES et al., 2011).

Em um PLF discreto, a seleção dos locais onde as novas instalações serão estabelecidas é restrita a um conjunto finito e conhecido de locais candidatos disponíveis. A configuração mais simples do problema é aquela em que as p instalações devem ser selecionadas para minimizar as distâncias ou custos totais (ponderados) para suprir as demandas dos clientes. Nesta configuração, o problema é chamado de p -medianas (MELO et al., 2007).

Quando os locais candidatos não são equivalentes em termos do custo de configuração para localizar um novo recurso, a função objetivo pode ser estendida com um termo para custos fixos de localização da instalação e, como resultado, o número de instalações a serem estabelecidas normalmente se torna uma das variáveis de decisão. Este novo cenário é conhecido na literatura como o problema de localização de instalações não capacitado (MELO et al., 2007).

No PLF não capacitado, presume-se que cada instalação não tem limite em sua capacidade de atendimento e cada cliente recebe toda a sua demanda de exatamente uma instalação enquanto o PLF capacitado consiste em decidir quais instalações abrir e como atribuir clientes às mesmas, de forma a suprir a demanda

dos clientes respeitando a capacidade de fornecimento de cada local candidato a instalação (ULUKAN; DEMIRCIOĞLU, 2015).

3.3.2.1 Procedimento Exato para o PLF

O PLF em sua configuração mais simples é também chamado de problema das p -medianas, que envolve a determinação da localização de p facilidades e designação dos clientes às p facilidades, com o objetivo de redução no tempo de deslocamento e de custo (ARENALES et al., 2011).

O problema das p -medianas pode ser solucionado de forma exata por meio do modelo matemático de Programação Linear Inteira Binária (PLIB) conforme apresentado de (1) a (6), de acordo com Senne e Lorena (2003):

$$Fun. Obj. = Min z = \sum_{i=1}^n \sum_{j=1}^n w_j d_{ij} x_{ij} \quad (1)$$

Sujeito a:

$$\sum_{i=1}^n x_{ij} = 1, \quad para j = 1, \dots, n \quad (2)$$

$$\sum_{i=1}^n x_{ii} = p \quad (3)$$

$$x_{ij} \leq x_{ii}, \quad para i, j de 1, \dots, n \quad (4)$$

$$x_{ij} = 1 \text{ ou } 0 \quad (5)$$

$$\sum_{j=1}^n x_{ij} q_j \leq x_{ii} c_i, \quad para i 1, 2, \dots, n \quad (6)$$

Onde:

x_{ij} = matriz de alocações, em que:

$x_{ij} = 1$, se o vértice j é alocado ao vértice i ; $x_{ij} = 0$, caso contrário;

$x_{ii} = 1$, se o vértice i é um vértice-mediana; $x_{ii} = 0$, caso contrário.

O número n corresponde ao número de pontos considerados; p = número de medianas a serem localizadas e d_{ij} é a matriz de distâncias ponderadas (distâncias com cada coluna j multiplicada pelo peso de w_j) e w_i = peso do vértice i .

A função objetivo em (1) busca a distância mínima entre os pontos de demanda e as medianas. As restrições (2) exigem que todo vértice j seja alocado a um único vértice-mediana i . Em (3) tem-se a definição do número de medianas (p) a serem encontradas. As restrições em (4) garantem que as alocações só podem ser feitas a vértices-medianas. As restrições em (5) indicam que as variáveis x_{ij} devem ser binárias podendo assumir os valores “0” ou “1”. Por fim, as restrições em (6) consideram as demandas q_j e as capacidades c_i .

3.3.2.2 Procedimentos Heurísticos para o PLF

Em função da formulação do PLF como um modelo de PLIB, sua resolução de forma exata, dependendo por exemplo da quantidade de nós candidatos envolvidos e da cardinalidade dos nós do grafo, se torna complexa ou até inviável em função do tempo de processamento computacional necessário. Assim, muitas heurísticas são propostas na literatura para a resolução do PLF. Nesta seção são apresentados alguns dos procedimentos heurísticos para a resolução do PLF, mais especificamente o algoritmo de Teitz & Bart, o algoritmo de Gillett e Johnson Modificado, o algoritmo de Vogel e os algoritmos First-Fit e First-Fit-Decreasing.

A. Algoritmo das p -medianas de Teitz & Bart (T&B)

O algoritmo desenvolvido por Teitz e Bart (1968), denominado de algoritmo das p -medianas de Teitz & Bart, baseia-se na substituição de vértices para encontrar uma solução para o PLF, ou seja, é desenvolvido por meio da troca de medianas presentes em uma dada solução visando a melhora do valor da função objetivo a cada iteração. De maneira simplificada, o algoritmo consiste em partir de uma solução aleatória inicial e a partir dela comparar um a um os nós que estão fora da solução atual, substituindo os nós mais bem colocados na função objetivo.

A heurística de T&B, descrita por Eiselt e Marianov (2011), pode ser definida da seguinte forma: seja $G(V, A)$ um grafo não direcionado onde V são os seus vértices e A as suas arestas. Seja v_i um vértice pertencente a V e sejam conhecidas as distâncias euclidianas entre todos os vértices de V . Denomina-se número de transmissão do vértice v_i , $\sigma(v_i)$, a soma das menores distâncias de todos os pontos

de demanda até as instalações mais próximas, ou seja, o número de transmissão de v_i é a distância total a ser percorrida desde v_i até todos os outros vértices do grafo. O valor de $\sigma(v_i)$ é dado pela equação (7), onde $d(v_i, v_j)$ é a menor distância entre v_i e v_j e w_j é o peso associado ao vértice v_j .

$$\sigma(v_i) = \sum_{j=1}^n w_j d(v_i, v_j), \quad v_i, v_j \in V \quad (7)$$

Assim, um vértice v_m é dito vértice mediana se a equação (8) for verdadeira, ou seja, será o vértice que possuir o menor número de transmissão:

$$\sigma(v_m) = \min\{\sigma(v_i)\} \quad \forall v_i \in V \quad (8)$$

Quando se deseja encontrar mais de uma mediana ($p > 1$), considera-se um conjunto de vértices (V_p) escolhidos aleatoriamente e com $V_p \in V$, em que a quantidade de vértices em V_p seja igual à quantidade de medianas a ser localizadas ($|V_p| = p$).

$$d(V_p, v_j) = \min\{d(v_i, v_j)\} \quad \forall v_i \in V_p, v_j \in V \quad (9)$$

$$\sigma(V_p) = \sum_{j=1}^n w_j d(V_p, v_j), \quad \forall v_j \in V \quad (10)$$

Um conjunto de p vértices é solução ótima para o problema das p -medianas se, dentre todos os outros conjuntos de p vértices do grafo, for o que corresponder a menor distância total desde si próprio até todos os outros vértices, ou seja, deve atender a equação (11). O objetivo do problema das p -medianas é, portanto, encontrar um conjunto V_p em V , para o qual o número de transmissão seja mínimo. A FIGURA 11 apresenta os passos do algoritmo de T&B.

$$\sigma(V_{p\text{SoluçãoÓtima}}) = \min\{\sigma(v_p)\} \quad \forall v_p \subset V \quad (11)$$

FIGURA 11 - PASSOS DO ALGORITMO HEURÍSTICO DE T&B

Algoritmo de Teitz & Bart

INÍCIO

Passo 1 – Selecionar um conjunto S , com $|S| = p$ vértices para formar uma solução inicial para o problema das p -medianas;

Passo 2 – Rotular todos os vértices $v_i \notin S$ como “não analisados”;

Passo 3 – Enquanto existirem vértices não analisados em $V-S$, faça: selecione o vértice v_i pertencente a $V-S$, não analisado, e calcule a redução do número de transmissão, para todo v_j pertencente a S , por meio de Δ_{ij} .

$$\Delta_{ij} = \sigma(S) - \sigma(S \cup \{v_i\} - \{v_j\})$$

Faça: $\Delta_{ijMáximo} = \max [\Delta_{ij}] \quad \forall \Delta_{ij}$ calculado anteriormente

Se $\Delta_{ijMáximo} > 0$ então:

Faça $S \leftarrow (S \cup \{v_i\} - \{v_j\})$

Rotule v_j como analisado;

Passo 4: Se durante a execução do Passo 3, houver alguma modificação no conjunto S , volte ao Passo 2, caso contrário, pare, e apresente o conjunto S com uma aproximação para a solução do problema da p -medianas.

FIM

FONTE: Teitz; Bart (1968).

B. Algoritmo de Gillett e Johnson Modificado

O algoritmo de Gillett e Johnson pode ser aplicado para alocação dos pontos de demanda aos pontos mediana, uma vez que as medianas estejam previamente determinadas. O algoritmo utiliza como fator de decisão para o agrupamento um valor representativo da “urgência” com que o ponto de demanda deve ser alocado. O critério de urgência consiste em determinar a razão entre a primeira e a segunda menor distância do ponto de demanda até a mediana. A designação é feita em ordem crescente do critério de urgência. Assim quanto menor este valor, mais prioritária é a alocação deste ponto à referida mediana uma vez que, a segunda mediana mais próxima fica em posição bem pior em relação ao ponto do que a primeira (BODIN et al., 1983; GONÇALVES et al., 2013).

Uma modificação no algoritmo originalmente proposto por Gillett e Johnson foi apresentada por Correa (2000) e consiste em considerar a diferença entre a segunda e primeira menor distância do ponto de demanda até a mediana ao invés da razão. A designação é feita em ordem decrescente das diferenças, obedecendo-se a capacidade. Desta forma, considerando-se a diferença, pontos que estejam relativamente próximos a uma mediana são considerados prioritários na designação. A FIGURA 12 apresenta os passos do algoritmo.

FIGURA 12 - PASSOS DO ALGORITMO DE GILLETT E JOHNSON MODIFICADO

Algoritmo de Gillett e Johnson Modificado**INÍCIO**

Passo 1 - Para todo ponto i não designado, faça:

Encontre $L1(i)$ e $L2(i)$ sendo a primeira e a segunda mediana mais próxima do ponto de demanda i onde a capacidade não esteja esgotada.

Calcule a diferença e coloque o ponto i na “lista de designação” pela ordem decrescente dos valores de $d(i)$. Inicie pelo topo da “lista de designação” designando o ponto de demanda i para a mediana mais próxima.

$$d(i) = L2(i) - L1(i)$$

Passo 2 - Enquanto houver pontos de demanda não designados, faça: designe o ponto de demanda atual para a mediana mais próxima da sua localização que disponibilize capacidade. Diminua uma unidade da capacidade da mediana de onde o ponto de demanda foi designado. Se a capacidade da mediana que recebeu o ponto de demanda atual está igual a zero (esgotado), então retorne ao Passo 1 e recalcule a “lista de designação”; caso contrário continue.

FIM

FONTE: Ferreira (2016).

C. Algoritmo de Vogel

O algoritmo de Vogel, que permite obter uma solução aproximada ao Problema de Transporte pode ser aplicado para obtenção de uma solução heurística do PLF. No contexto de resolução do PLF, o método se aplica para definição dos *clusters*, ou seja, para a designação dos pontos de demanda às medianas previamente definidas.

De acordo com Goldbarg et al. (2016), o método consiste em calcular para cada linha (referente à oferta) e para cada coluna (referente à demanda) a diferença entre os dois menores custos, denominada penalização. O método prioriza as linhas e colunas da matriz em que há uma maior “urgência” em se fazer a designação, ou seja, as linhas e colunas nas quais as diferenças entre os dois menores custos é muito grande (penalização alta). Os passos detalhados do algoritmo são descritos na FIGURA 13.

FIGURA 13 - PASSOS DO ALGORITMO DE VOGEL

Algoritmo de Vogel**INÍCIO**

Passo 1 - Determinar a diferença entre os dois menores custos de cada linha e cada coluna.

Passo 2 - Selecionar a linha (ou coluna) de maior diferença (maior penalização). Caso ocorra empate, escolha aleatoriamente.

Passo 3 - Na coluna (ou linha) escolhida, atribuir, na célula de menor custo ainda sem alocação, a maior quantidade possível de suprimento.

Passo 4 - Atualize as ofertas (e demandas), subtraindo a quantidade de suprimento atribuída. As linhas ou colunas em que a oferta ou demanda já foi satisfeita devem ser eliminadas nas próximas etapas. Se não restar mais linhas ou colunas a serem preenchidas, pare. Caso contrário, volte ao Passo 2.

FIM

FONTE: Adaptado de Belfiore; Fávero (2013).

D. Algoritmo *First-Fit* (FF)

O algoritmo *First-Fit* (FF) é uma técnica utilizada para resolução do Problema de Corte e Empacotamento que consiste na combinação de unidades menores (itens) dentro de unidades maiores (recipientes) de forma otimizada. Esta técnica pode ser adaptada ao PLF para definição dos *clusters*, para a designação dos pontos de demanda às medianas previamente determinadas, onde as medianas correspondem as caixas às quais os pontos de demanda (objetos de tamanho correspondente a sua demanda) devem ser alocados.

Este algoritmo processa os itens de entrada um por um, seu funcionamento ocorre da seguinte maneira: cada item é empacotado no primeiro recipiente, ou seja, aquele que corresponda ao menor índice de posição, que tenha espaço suficiente para o item. Uma nova posição (recipiente) é criada apenas quando um item não se encaixa nos recipientes anteriores. Como a varredura é feita sempre em ordem crescente pelos índices dos recipientes abertos, o FF tende a concentrar os itens nos primeiros recipientes (DÓSA; EPSTEIN, 2018).

E. Algoritmo *First-Fit-Decreasing* (FFD)

O algoritmo *First-Fit-Decreasing* (FFD) tem funcionamento similar ao algoritmo *First-Fit*, porém a alocação dos itens aos recipientes neste caso se dá em ordem decrescente do tamanho do objeto (DÓSA; EPSTEIN, 2018).

3.3.3 Problema do Caixeiro Viajante – PCV

Um dos problemas clássicos de roteamento de veículos, o PCV, mais conhecido sob seu nome em inglês *Traveling Salesman Problem* (TSP), foi introduzido em 1954 por Dantzig. O problema consiste em definir o trajeto de um vendedor que deve visitar certo número de cidades e retornar à cidade de partida, com o objetivo de minimizar a distância total percorrida (DANTZIG; FULKERSON; JOHNSON, 1954).

O objetivo do PCV é determinar um ciclo ou circuito de custo mínimo, visitando um conjunto de n nós da rede. Em outras palavras, o problema concerne a busca de um caminho hamiltoniano (saindo de um ponto origem, passando por todos os nós

uma única vez e retornando à origem) de custo mínimo, custo este que pode ser representado pela distância (HAJ RACHID, 2010).


O PCV integra uma classe de problemas de otimização mais ampla, definida como: Problema de Roteirização de Veículos (PRV) conhecido também sob seu nome em inglês *Vehicle Routing Problem*. O PRV foi formulado em 1959 pela continuação dada aos estudos de Dantzig, e constitui uma das generalizações do PCV que permite a modelagem e resolução de alguns dos problemas de transporte operacionais (DANTZIG; RAMSER, 1959).

Segundo Laporte (2009), na prática os PRV podem ser considerados uma classe de problemas de otimização, pois diversas variantes do problema são observadas em situações reais. Isso se deve a adição de restrições e a diversidade de regras operacionais em cada tipo de ramo de negócios.

O PRV pode ser caracterizado por: (1) os n clientes são atendidos por m veículos que partem e retornam ao depósito; (2) cada veículo deve satisfazer a quantidade de demanda total de cada cliente; (3) cada cliente deve ser atendido uma única vez por um único veículo; (4) a quantidade total da demanda dos n clientes atendidos por cada m veículo não deve exceder a restrição de capacidade do veículo (DANTZIG; RAMSER, 1959).

A FIGURA 14 apresenta a comparação entre um PCV e um PRV em relação ao traçado das rotas em uma dada solução para um conjunto semelhante de clientes. A diferença principal consiste em uma rota única para atendimento de todos os clientes no caso do PCV e de múltiplas rotas no caso do PRV.

FIGURA 14 - ILUSTRAÇÃO DE ROTA EM UM PCV E DE MÚLTIPLAS ROTAS EM UM PRV



FONTE: A autora (2019).

LEGENDA: a) Representação do PCV.

b) Representação do PRV.

3.3.3.1 Modelo Matemático

Conforme apresentado por Belfiore e Fávero (2013), pode-se abordar o PCV como um problema de otimização associado à determinação dos caminhos hamiltonianos em um grafo qualquer. Considere $G = (N, A)$ um grafo não orientado em que N é o conjunto de n cidades (nós) e A é o conjunto de arcos entre as cidades. Assim, o objetivo do PCV é encontrar, no grafo $G(N, A)$, o caminho hamiltoniano de menor custo que inicia em uma determinada cidade, visita todos os nós uma única vez, e retorna à cidade de origem. A seguir é apresentada a formulação para o PCV elaborada por Dantzig, Fulkerson e Johnson (1954).

Variáveis de decisão:

$$x_{ij} = \begin{cases} 1 & \text{se o caixeiro viajante vai diretamente da cidade } i \text{ para a cidade } j, i \neq j \\ 0 & \text{caso contrário} \end{cases}$$

Parâmetros do modelo:

$$c_{ij} = \text{custo ou distância da cidade } i \text{ para a cidade } j, i = 1, \dots, n \text{ e } j = 1, \dots, n$$

Formulação:

$$\text{Fun. obj} = \min z = \sum_{i=1}^n \sum_{j=1}^n c_{ij} x_{ij} \quad (12)$$

Sujeito a:

$$\sum_{i=1}^n x_{ij} = 1 \quad \forall j \in N \quad (13)$$

$$\sum_{j=1}^n x_{ij} = 1 \quad \forall i \in N \quad (14)$$

$$\sum_{i,j \in S} x_{ij} \leq |S| - 1 \quad \forall S \subset N \quad (15)$$

$$x_{ij} \in \{0,1\} \quad \forall i,j \in N \quad (16)$$

Como as variáveis de decisão são binárias (16), a formulação corresponde a um modelo de Programação Linear Inteira Binária (PLIB), onde a variável binária x_{ij}

assume valor igual a 1, se o arco $(i, j) \in A$ for escolhido para integrar a solução e 0 em caso contrário.

A função objetivo (12) busca minimizar o custo ou a distância total percorrida. As restrições (13) e (14) garantem que cada nó seja visitado uma única vez. A restrição (15) é adicionada para que se evitem os subgrafos, onde S representa um subgrafo de G , em que $|S|$ representa o número de vértices desse subgrafo.

Quando o interesse é efetuar o planejamento de rotas para mais de um caixeiro, o clássico PCV dá lugar ao Problema dos Múltiplos Caixeiros Viajantes (PMCV), onde o objetivo é obter m rotas, todas partindo e retornando ao mesmo ponto, comumente e por situações práticas denominados depósito.

A formulação matemática para o PMCV, onde $G = (N, A)$ corresponde a um grafo orientado completo em que N é o conjunto de n cidades (nós) e A é o conjunto de arcos entre as cidades, onde m caixeiros viajantes parte de um depósito (denotado pelo nó 0) para visitar n cidades, é apresentada nas equações de (17) a (23) conforme proposto por Arenales et al. (2011):

Variáveis de decisão:

$$x_{ij} = \begin{cases} 1 & \text{se o caixeiro viajante vai diretamente da cidade } i \text{ para a cidade } j, i \neq j \\ 0 & \text{caso contrário} \end{cases}$$

Parâmetros do modelo:

$$c_{ij} = \text{custo ou distância do nó } i \text{ para o nó } j, i = 0, 1, \dots, n \text{ e } j = 0, 1, \dots, n$$

Formulação:

$$\text{Fun. obj} = \min z = \sum_{i=0}^n \sum_{j=0 \text{ e } j \neq i}^n c_{ij} x_{ij} \quad (17)$$

Sujeito a:

$$\sum_{j=1}^n x_{0j} = m \quad (18)$$

$$\sum_{i=1}^n x_{i0} = m \quad (19)$$

$$\sum_{i=1}^n x_{ij} = 1 \quad \forall j \in N, \quad j \neq i \quad (20)$$

$$\sum_{j=1}^n x_{ij} = 1 \quad \forall i \in N, \quad i \neq j \quad (21)$$

$$\sum_{i,j \in S} x_{ij} \leq |S| - 1 \quad S \setminus \{0\} \subset N \quad 2 \leq |S| \leq [n/2] \quad (22)$$

$$x_{ij} \in \{1,0\} \quad \forall i,j \in N \quad (23)$$

A função objetivo em (17) busca minimizar as distâncias totais a serem percorridas pelos m caixeiros viajantes. Em (18) tem-se a restrição de que os m caixeiros devem iniciar sua rota no depósito (nó 0) e de maneira semelhante em (19) tem-se a indicação de que as m rotas devem finalizar no depósito (nó 0). As restrições em (20) e (21), de maneira semelhante ao modelo de um único caixeiro em (13) e (14), garantem que cada nó seja visitado uma única vez. A restrição (22) é referente à eliminação de sub-rotas. Em (23) o domínio das variáveis de decisão x_{ij} é definido como binário.

Segundo Bodin et al. (1983), existem duas diferentes estratégias para o PMCV:

- I) Determinar rotas de maneira mais simples, a partir de uma primeira divisão dos nós de determinada região em agrupamentos menores (*cluster first, route second*).
- II) Determinar uma rota contendo todos os nós da região e então dividir em sub-rotas cobertas pelo número de caixeiros disponíveis (*route first, cluster second*).

3.3.3.2 Procedimentos Heurísticos para o PCV

Sendo o PCV classificado como NP-hard² conforme demonstrado por Karp (1972), diversos procedimentos heurísticos são aplicados para sua resolução.

Conforme Bodin et al. (1983), os métodos heurísticos para resolver o PCV podem ser enquadrados nas seguintes categorias:

- Procedimentos de Construção de Rotas;
- Procedimentos de Melhoria de Rotas;
- Procedimentos Compostos (Construção + Melhoria).

² Problemas da classe NP-hard são aqueles cujo grau de dificuldade na resolução aumenta exponencialmente conforme o tamanho do problema abordado, ou seja, onde muitas vezes o tempo computacional exigido para resolução de forma exata é proibitivo.

As próximas seções apresentam o detalhamento das categorias de construção de rotas e de melhoria de rotas.

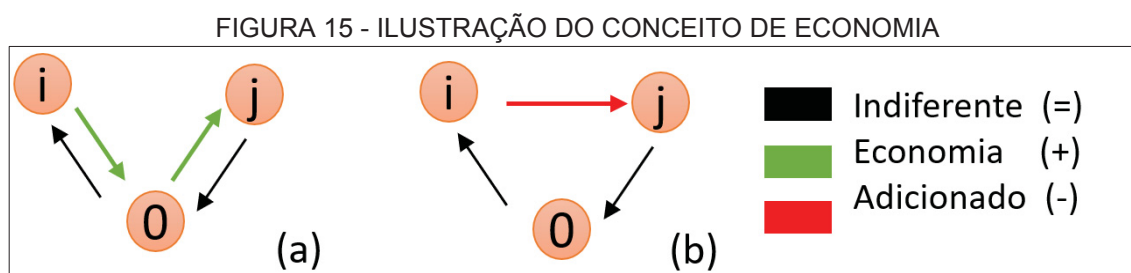
A. Procedimentos de Construção de Rotas

De acordo com Bodin et al. (1983), os procedimentos de construção de rotas criam rotas por meio da adição sucessiva (conforme algum critério estabelecido) de clientes ainda não visitados nas rotas em formação. Podem ser destacados como métodos heurísticos desta classe o algoritmo dos *Savings* (economias) de Clarke e Wright (C&K) e algoritmos de inserção, detalhados na sequência.

i. Algoritmo dos *Savings* (economias) de Clarke e Wright (C&W)

A heurística apresentada por Clarke e Wright (1964), conhecida por Algoritmo dos *Savings* (economias) de Clarke e Wright (C&W), baseia-se na noção de economias, que podem ser definidas como o custo da combinação, ou união, de duas sub-rotas existentes. Inicialmente, cada cliente é servido por um veículo, constituindo rotas entre o depósito e cada cliente. A formação do roteiro sempre ocorre a partir da combinação dos extremos das rotas iniciais, a fim de gerar uma rota final com todos os n pontos de demanda. Verifica-se assim, a possibilidade de trocar dois roteiros por um único, visando maximizar as economias.

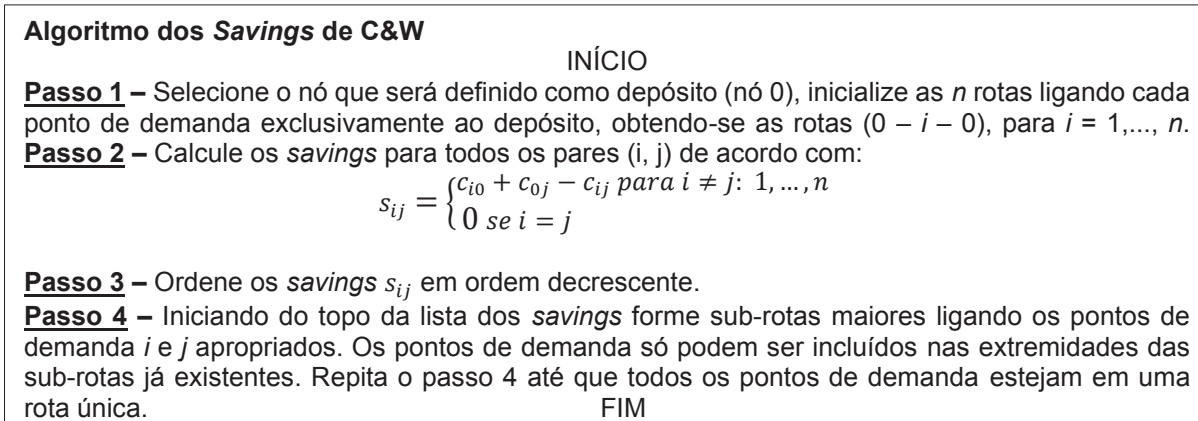
Seja o nó 0 o depósito e c_{ij} o custo de viagem partindo de um cliente i a um cliente j . As economias são calculadas para todos os pares (i, j) conforme a equação $s_{ij} = c_{i0} + c_{0j} - c_{ij}$. A FIGURA 15 mostra a redução de custo obtida por se juntar duas ou mais rotas, como descrito em (a), em uma única (b). Os passos do algoritmo de C&W são descritos na FIGURA 16.



FONTE: A autora (2019).

LEGENDA: a) Representação de rotas múltiplas com único cliente.
b) Representação da junção de rotas em rota única.

FIGURA 16 - PASSOS DO ALGORITMO DOS SAVINGS DE C&W



FONTE: Adaptado de Clarke e Wright (1964)

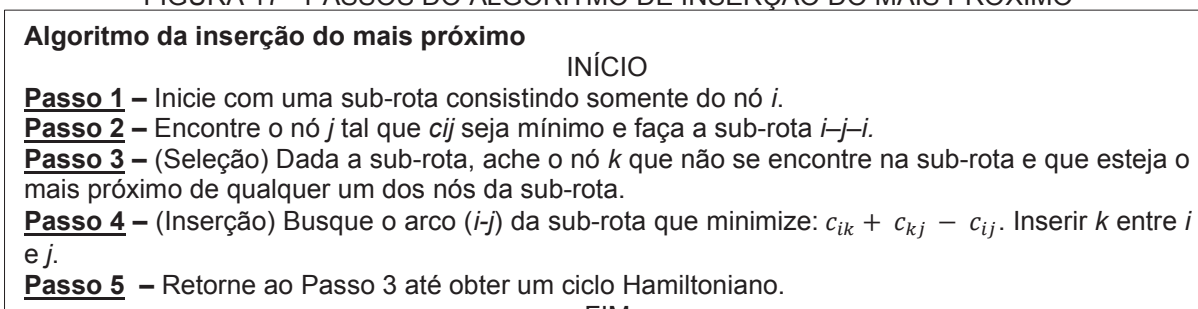
ii. Algoritmos de Inserção

Um procedimento de inserção considera a construção iterativa e progressiva da rota em duas etapas: (1) seleção e (2) inserção. Partindo de uma sub-rota com k nós, a cada iteração determina qual o próximo nó a ser visitado e a posição que este nó deve ser inserido na sub-rota. A seguir, são detalhados alguns dos procedimentos de inserção propostos originalmente por Rosenkrantz et al. (1977) e também apresentados e discutidos por Bodin et al. (1983).

a) Inserção do mais próximo

Neste algoritmo a rota é construída envolvendo 3 decisões principais: (1) escolha do ciclo inicial, contendo o vértice de origem i e o vértice j mais próximo do vértice de origem, (2) a seleção do vértice a ser inserido na rota atual tal que a distância entre o vértice k e todos os vértices que estão na rota seja mínima e (3) a posição de inserção desse novo vértice. Os passos do algoritmo são descritos na FIGURA 17.

FIGURA 17 - PASSOS DO ALGORITMO DE INSERÇÃO DO MAIS PRÓXIMO



FONTE: adaptado de Rosenkrantz et al. (1977), Bodin et al. (1983).

Esta heurística tem a variante “Inserção mais distante” que substitui o passo 3, por: (Seleção) Dada a sub-rota, ache o nó k que não se encontre na sub-rota e que esteja o mais **distante** de qualquer um dos nós da sub-rota e o passo 4 por: (Inserção) Busque o arco $(i-j)$ da sub-rota que **maximize**: $c_{ik} + c_{kj} - c_{ij}$. Inserir k entre i e j .

b) Inserção do Mais Barato

Neste algoritmo a rota é construída partindo de uma rota inicial envolvendo 3 cidades e adicionando a cada iteração, a cidade k , ainda não visitada, entre a ligação (i, j) das cidades já visitadas, cujo custo de inserção seja o mais barato. O custo da inserção é calculado por: custo $(i, k) +$ custo $(k, j) -$ custo (i, j) , onde i e j são os vértices já visitados e k o vértice a ser inserido na solução final. Os passos do algoritmo são descritos na FIGURA 18.

FIGURA 18 - PASSOS DO ALGORITMO DE INSERÇÃO DO MAIS BARATO

Algoritmo da inserção do mais barato	INÍCIO
Passo 1 – Inicie com uma sub-rota consistindo somente do nó i .	
Passo 2 – Encontre o nó j tal que c_{ij} seja mínimo e faça a sub-rota $i-j-i$.	
Passo 3 – (Seleção) Encontre o arco (i, j) na sub-rota e o nó k (que não pertence a sub-rota) tal que: $c_{ik} + c_{kj} - c_{ij}$ seja minimizado.	
Passo 4 – (Inserção) Inserir k entre i e j .	
Passo 5 – Retorne ao Passo 3 até obter um ciclo Hamiltoniano.	
	FIM

FONTE: adaptado de Rosenkrantz et al. (1977), Bodin et al. (1983)

c) Inserção Rápida ou Adição do vizinho mais próximo

Este algoritmo consiste em construir uma rota passo a passo, adicionando à solução corrente a cidade mais próxima (e ainda não visitada) da última cidade inserida. Os passos do algoritmo são descritos na FIGURA 19.

FIGURA 19 - PASSOS DO ALGORITMO DE INSERÇÃO RÁPIDA OU VIZINHO MAIS PRÓXIMO

Algoritmo da inserção rápida ou adição do vizinho mais próximo	INÍCIO
Passo 1 – Escolha qualquer nó para formar um circuito de partida T , com um nó (e 0 arestas).	
Passo 2 – (Seleção) Dado o circuito de nó k (T_k), encontre o nó z (que não esteja em T_k) que está mais próximo de k , chame-o de y_k , em T_k .	
Passo 3 – (Inserção) Seja T_{k+1} , o circuito do nó $k + 1$ obtido inserindo-se z_k imediatamente à frente de y_k em T_k .	
Passo 4 – Repita os passos 2 e 3 até que um circuito hamiltoniano (contendo todos os nós) seja formado	FIM

FONTE: adaptado de Rosenkrantz et al. (1977), Bodin et al. (1983)

B. Procedimentos de Melhoria de Rotas

Procedimentos de melhoria de rotas tentam encontrar uma rota melhor, em termos da função objetivo, dada uma rota inicial. Os métodos de melhoria *k-opt* buscam pela substituição de arcos, ou seja, por meio de mudanças na rota inicial, refinar a solução encontrada iterativamente até que não haja mais possibilidade de melhoria. O número de arcos manipulados corresponde ao número (k) que faz parte da nomenclatura do método. Para a realização da operação de melhoria o algoritmo remove k arcos da rota atual, substituindo-os por outros k arcos não consecutivos. O procedimento termina quando não houver mais solução viável que promova melhora no valor da função objetivo, como por exemplo distância total da rota ou tempo total (LAPORTE, 2010). As heurísticas *2-opt* e *3-opt* foram introduzidas por Lin (1965) e o procedimento *k-opt*, para $k \geq 3$, foi apresentado por Lin e Kernighan (1973). Um pseudocódigo geral para a heurística de *k-opt* é apresentado na FIGURA 20.

FIGURA 20 - PSEUDOCÓDIGO DA HEURISTICA DE MELHORIAS DE ROTAS *k-OPT*

Algoritmo de Melhoria de Rotas *k-opt*

INÍCIO

Passo 1 – Obtenha por meio de algum algoritmo uma rota H , factível para o TSP.

Passo 2 – Remova k arestas da solução H obtendo uma solução H' .

Passo 3 – Construa todas as soluções viáveis contendo H' .

Passo 4 – Escolha a melhor solução dentre as encontradas e armazene como *best_solution*.


Passo 5 – Escolha outro conjunto de k arestas ainda não selecionadas e retornar ao passo 2, caso contrário, pare e apresente a solução armazenada em *best_solution* como rota melhorada.

FIM

FONTE: adaptado de Rego e Glover (2007)

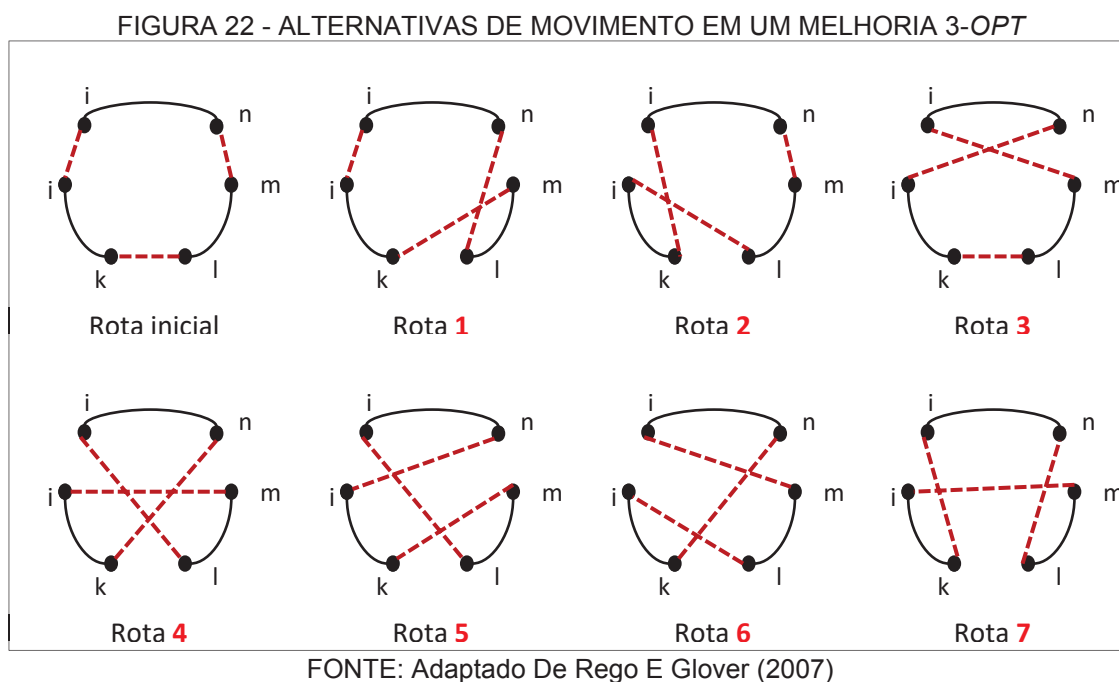
O método *2-opt* consiste na troca de dois arcos que são desligados e substituídos por outros dois de modo que a distância total na nova rota formada seja menor que na rota inicial. A FIGURA 21 ilustra as possíveis trocas em uma heurística de melhorias *2-opt*, ao remover 2 arestas, há apenas uma solução de rota alternativa.

FIGURA 21 - ALTERNATIVAS DE MOVIMENTO EM UM MELHORIA 2-OPT



FONTE: adaptado de Rego e Glover (2007)

Analogamente as trocas da heurística *2-opt*, ocorrem as trocas na heurística *3-opt*, onde três arcos são permutados. A FIGURA 22 ilustra as possibilidades de troca para um procedimento *3-opt*, ao remover 3 arestas existem 8 rotas alternativas possíveis, totalizando 8 opções de reconexão diferentes.



3.3.4 Procedimentos Meta-heurísticos para o PLF e para o PCV

A seguir são apresentadas as meta-heurísticas Algoritmo Genético e *Simulated Annealing* aplicáveis para solucionar o PLF e o PCV.

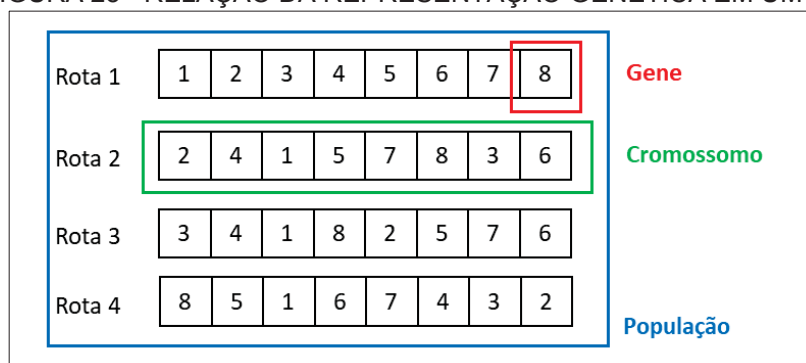
3.3.4.1 Algoritmo Genético

O Algoritmo Genético (AG) é um dos primeiros algoritmos estocásticos de base populacional propostos na história. Introduzido pelos estudos de Holland (1975), e popularizado por Goldberg (1989), o AG tem sua inspiração no trabalho de Darwin e Mendel sobre o processo de evolução das espécies. Os AG são diferentes da maioria das outras meta-heurísticas porque exploram três ideias-chave: (1) o uso de uma população de soluções para orientar a pesquisa; (2) o uso de operadores genéticos que recombina duas ou mais soluções para gerar soluções novas potencialmente

melhores e (3) o gerenciamento ativo da diversidade para sustentar a exploração do espaço de busca (WHITLEY, 2019).

Em contraste com as técnicas de otimização tradicionais, os AG trabalham com codificação de parâmetros, em vez dos próprios parâmetros, correspondendo a representação genética. Assim, as n variáveis de decisão de um problema são representadas em cadeias de comprimento finito (vetores de tamanho n). Estes vetores, que são soluções candidatas ao problema de otimização, são chamadas de cromossomos (ou indivíduos), os caracteres que compõem o vetor são chamados de genes e os valores dos genes são chamados de alelos. E um conjunto de soluções candidatas é chamado de população. Por exemplo, em um problema como o PCV, um cromossomo representa uma rota (sequência de cidades a serem visitadas) e um gene representa cada cidade. A FIGURA 23 demonstra relação entre cromossomos, genes e alelos para o caso de um PCV, onde cada indivíduo corresponde a uma rota.

FIGURA 23 - RELAÇÃO DA REPRESENTAÇÃO GENÉTICA EM UM AG



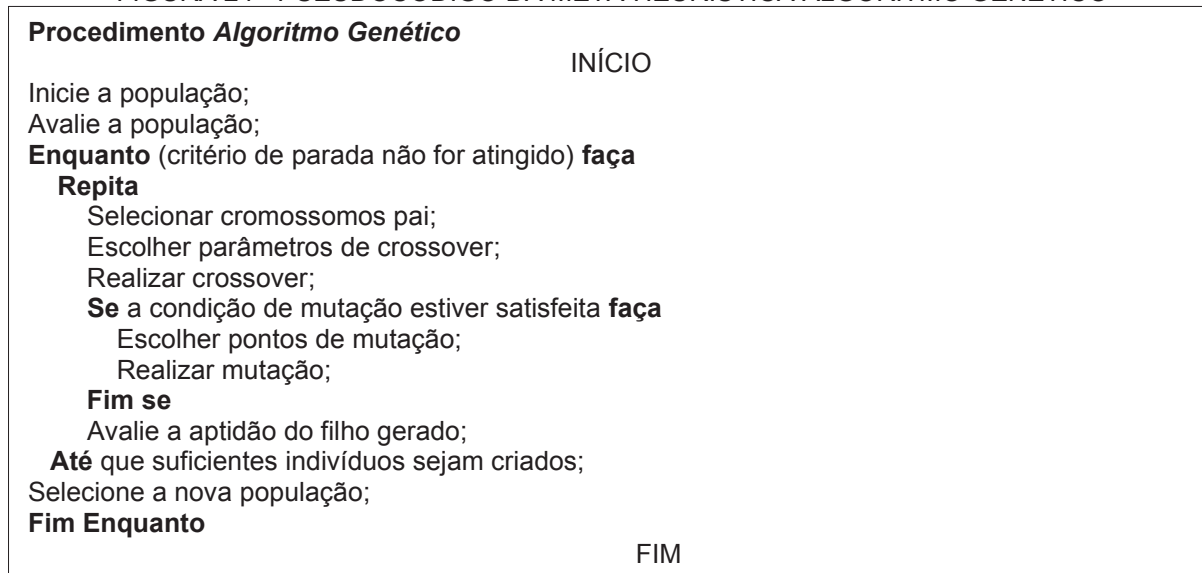
FONTE: A autora (2019).

São componentes básicos dos AG: a sua representação genética, a população inicial, a função de avaliação, o método de seleção de reprodução, os operadores genéticos, o método de seleção de gerações, os critérios de parada e os parâmetros de configuração. Um pseudocódigo geral para o funcionamento do AG é apresentado na FIGURA 24, onde diferentes formas de seleção, crossover e mutação podem ser empregadas.

O objetivo principal na etapa de inicialização é “espalhar” as soluções em torno do espaço de busca o mais uniformemente possível para aumentar a diversidade da população e ter uma melhor chance de encontrar regiões promissoras. A população inicial de soluções candidatas é geralmente gerada aleatoriamente no espaço de pesquisa. No entanto, o conhecimento específico do domínio do problema

ou outras informações podem ser facilmente incorporadas para a criação de soluções iniciais (MIRJALILI, 2019).

FIGURA 24 - PSEUDOCÓDIGO DA META-HEURÍSTICA ALGORITMO GENÉTICO



FONTE: adaptado de Reeves (2010)

O AG usa a aptidão como um discriminador da qualidade das soluções representadas pelos cromossomos em uma população. O componente de seleção de um AG é projetado para usar a aptidão para guiar a evolução dos cromossomos que são selecionados para recombinação com base na aptidão. Aqueles com maior aptidão devem ter uma maior chance de seleção do que aqueles com menor aptidão, criando assim uma pressão seletiva para obtenção de soluções mais adequadas. O esquema original para sua implementação é comumente conhecido como o método da roda de roleta. Ele usa uma distribuição de probabilidade para seleção na qual a probabilidade de seleção de um determinado indivíduo é proporcional à sua adequação (REEVES, 2010).

Esse mecanismo simula a seleção natural do indivíduo mais apto na natureza. Como uma roleta é um operador estocástico, os indivíduos “mais fracos” (com menor aptidão à função objetivo) têm uma pequena probabilidade de participar na criação da próxima geração. Se uma solução “fraca” é “sortuda” e então selecionada, seus genes passam para a próxima geração. Descartar tais soluções reduziria a diversidade da população drasticamente, o que deve ser evitado (REEVES, 2010).

O elitismo é um mecanismo pelo qual a melhor solução na geração t é colocada diretamente na população na geração $t + 1$. O elitismo também pode ser

parametrizado de modo que um número constante dos melhores indivíduos seja colocado diretamente na próxima geração. Isso também tem o efeito colateral de aumentar a pressão seletiva, uma vez que reduz o número de posições disponíveis que podem ser preenchidas na população por cadeias recém-criadas produzidas por recombinação e/ou mutação (WHITLEY, 2019).

Uma vez que os indivíduos “pais” estejam selecionados, o papel da fase de reprodução (ou recombinação) é a aplicação de operadores de variação, tais como a mutação e crossover para obter novas soluções (descendentes), possivelmente com melhores valores de aptidão (BOZORG-HADDAD et al., 2017).


O operador de *crossover* obtém novos descendentes por meio da substituição de alguns dos genes de um dos pais pelos genes correspondentes do outro. A maneira mais simples é escolher aleatoriamente algum ponto de cruzamento, fragmentar tanto o pai 1 quanto o pai 2 neste dado ponto e recombinar as “partes” para a criação de novos indivíduos. Esse procedimento é denominado de crossover de ponto único. Analogamente, descreve-se o crossover de n pontos, onde n pontos de cruzamento são selecionados e a troca de material genético entre os pais 1 e 2 é então realizada para obter-se o novo indivíduo (KORA; YADLAPALLI, 2017).

Alguns operadores de crossover foram especialmente desenvolvidos para codificação de cromossomos por permutação, como é o caso do PCV onde a ordem da visita é representada pela sequência numérica de cada gene em um dado indivíduo. São exemplos de operadores de crossover especialmente desenvolvidos para o PCV, *Order-Based Crossover* (OBX), *Position-Based Crossover* (PBX), *Partially Matched Crossover* (PMX), *Cycle Crossover* (CX), *Order Crossover* (OX), *Heuristic crossover* (HX), entre outros (UMBARKAR; SHETH, 2015).

Para introduzir novas variações e explorar localmente o espaço de busca da população atual, podem ser introduzidos operadores de mutação. A variação genética pode ser introduzida por meio de uma mudança aleatória em uma solução. A probabilidade para que esta mudança aleatória aconteça é denominada de taxa de mutação. Alguns exemplos podem ser vistos na FIGURA 25, onde a representação genética corresponde a um problema de codificação por permutação, como é o caso do PCV. Em (a), representa-se a mutação baseada em posição, onde retira-se elemento da posição i e insere-se na posição j , sendo i e j dois valores aleatórios. Em (b), tem-se a mutação baseada em ordem, onde troca-se o elemento da posição i com

o da j , sendo i e j dois valores aleatórios, e por fim em (c), mutação 2-*opt*, onde a partir de dois pontos sorteados, (i e j) o segmento entre eles é revertido (WHITLEY, 2019).

FIGURA 25 - EXEMPLOS DO OPERADOR DE MUTAÇÃO EM UM PROBLEMA DE CODIFICAÇÃO POR PERMUTAÇÃO



FONTE: adaptado de WHITLEY (2019)

LEGENDA: a) Representação de mutação baseada em posição.

b) Representação de mutação baseada em ordem.

c) Representação de mutação baseada no movimento 2-*opt*.

Em razão de suas características, os AG evitam atrações irremediáveis para ótimos locais, o que pode ocorrer frequentemente com alguns outros métodos heurísticos e meta-heurísticos, permitindo assim uma melhor exploração do espaço de busca. O que torna o método confiável e capaz de estimar o ótimo global (ou obter uma solução quase ótima) para um determinado problema é o processo de manter as melhores soluções em cada geração e usá-las para melhorar outras soluções (abordagem elitista). Como tal, toda a população se torna melhor geração a geração (BOZORG-HADDAD et al., 2017).

3.3.4.2 Simulated Annealing

A técnica proposta por Kirkpatrick et al. (1983) baseada no trabalho de Metropolis et al. (1953), denominada *Simulated Annealing* (SA; ou Recozimento Simulado), faz uma analogia ao processo utilizado em metalurgia no tratamento térmico de metais, para alterar suas propriedades físicas devido às mudanças em sua estrutura interna. No recozimento, o metal é aquecido a uma temperatura elevada e em seguida resfriado lentamente para que os átomos possam se reorganizar utilizando uma quantidade mínima de energia, de modo que a estrutura do produto final se torne homogênea.

O SA é um algoritmo de busca local estocástico que, a partir de uma solução inicial, explora iterativamente a vizinhança da solução atual (FRANZIN; STUTZLE, 2019).

A principal característica do SA e principal diferença para outros métodos de busca local é que ele fornece um meio probabilístico de escapar dos ótimos locais, permitindo movimentos que pioram o valor da função objetivo na esperança de encontrar um ótimo global (DELAHAYE et al., 2019).

Para tornar o processo de SA análogo ao processo de recozimento físico, a função objetivo é definida como equivalente a energia do sólido. O processo inicia com uma solução inicial (s), denotando o estado inicial e utiliza soluções aleatórias a fim de otimizar a solução atual. Inicialmente, também considera-se um alto valor para o parâmetro de temperatura inicial, para o qual uma nova solução é gerada em função da vizinhança da solução atual. Se durante a execução surgirem soluções melhores que a solução atual, elas são sempre aceitas como nova solução para o problema e como solução a partir da qual a vizinhança será explorada. Caso a nova solução encontrada não melhore o valor da função objetivo ela poderá ser aceita como novo “centro de busca”, se conforme a equação (24), p for maior que um número $\epsilon [0, 1]$, gerado randomicamente, constituindo o critério probabilístico do SA (KRIPKA; KRIPKA, 2013).

$$p = \exp\left(\frac{-\Delta E}{T}\right) \quad (24)$$

Onde: p = função aceite da nova solução gerada aleatoriamente; ΔE = variação da função objetivo (ou variação da energia) entre o valor da solução e a solução vizinha; T = parâmetro de temperatura que mede a probabilidade de piora da função objetivo.

Existem diversas formas para obtenção da temperatura inicial, cita-se aqui dois exemplos conforme equações (25) e (26):

$$T_0 = \ln(f(s)) \quad (25)$$

Onde $f(s)$ corresponde ao valor da função objetivo para a solução inicial.

$$T_0 = - \frac{\Delta E^+}{\ln(\xi_0)} \quad (26)$$

Onde ΔE^+ corresponde à média aritmética, para um número randômico de perturbações, dos incrementos da função objetivo, e ξ_0 é um valor empírico, em torno de 0,8. No último caso, porém, o cálculo pode consumir muito tempo computacional. Por isso, frequentemente, usa-se uma estimativa para T_0 .

Para valores altos de T , início da execução do algoritmo, a chance de aceitação de soluções piores será maior. Durante as iterações do SA, o valor de T decresce

devido ao fator de redução α , $0 < \alpha < 1$, até que o critério de parada seja satisfeito. Também, a cada uma das iterações, a partir da solução atual (s), uma nova solução vizinha de s (s'), é gerada e é realizada a avaliação do valor da função objetivo, $\Delta E = f(s') - f(s)$, e três situações podem ocorrer:

- a) $\Delta E < 0$: há redução de energia, a nova solução s' é aceita e passa a ser a nova solução;
- b) $\Delta E = 0$: não ocorre alteração de energia, a nova solução s' é aceita e passa a ser a nova solução;
- c) $\Delta E > 0$: há um aumento de energia, a solução depende do critério probabilístico para ser aceita (havendo maior probabilidade em altas temperaturas).

O procedimento termina quando a temperatura T chega próximo de zero, quando as soluções que pioram a função objetivo muito dificilmente são aceitas, o que demonstra que o sistema está estável e evidencia o encontro de um mínimo local. (KRIPKA; KRIPKA, 2013).

Um algoritmo básico para o procedimento do SA é demonstrado na FIGURA 26.

No próximo capítulo são descritas detalhadamente, as técnicas utilizadas neste trabalho para resolução do PRV (estudo de caso em questão para a entrega de jornais) bem como descritas as etapas desenvolvidas na condução do estudo.

FIGURA 26 - PSEUDOCÓDIGO DA META-HEURÍSTICA SIMULATED ANNEALING

Procedimento *Simulated Annealing*

INÍCIO

$s^* \leftarrow s$; // { Melhor solução obtida até então }
 $IterT \leftarrow 0$; // { Número de iterações na temperatura T }
 $T \leftarrow T_0$; // { Temperatura Corrente }
 $S_{Amax} = \$$; // { Critério de parada para dada temperatura }

Enquanto ($T > 0$) **faça** **Enquanto** ($IterT < S_{Amax}$) **faça** $IterT \leftarrow IterT + 1$; Gere um vizinho qualquer $s' \in N(s)$; $\Delta E = f(s') - f(s)$; **se** ($\Delta E < 0$) **então** $s \leftarrow s'$; **se** ($f(s') < f(s^*)$) **então** $s^* \leftarrow s'$ **fim se** **senão** Tome $rand \in [0,1]$; **se** ($rand < e^{-\frac{\Delta E}{T}}$) **então** $s \leftarrow s'$ **fim se** **fim senão** **fim enquanto** $T \leftarrow \alpha \times T$; $IterT \leftarrow 0$;**Fim enquanto** $s \leftarrow s^*$;Retorne s

FIM

FONTE: adaptado de Kripka; Kripka (2013)

4 METODOLOGIA

O presente capítulo aborda os aspectos metodológicos empregados nesta pesquisa. O mesmo é dividido em três partes, sendo a primeira a apresentação da caracterização metodológica, a segunda, a descrição das etapas desenvolvidas na condução do estudo, a terceira o detalhamento da abordagem de solução e do método de resolução a serem aplicados na resolução do problema.

4.1 CARACTERIZAÇÃO DA METODOLOGIA DE PESQUISA

Segundo Cooper e Schindler (2016) é possível classificar as pesquisas quanto a sua natureza em pesquisas aplicadas ou pesquisas básicas. Pesquisas aplicadas são aquelas que visam descobrir soluções para problemas ou oportunidades imediatas. Assim, em relação a natureza da pesquisa, este estudo possui características de pesquisa aplicada, pois visa a otimização do atendimento aos clientes finais de um serviço de entrega de jornais na cidade de Curitiba.

Quanto a forma de abordagem, este estudo pode ser caracterizado como quantitativo, que de acordo com Fonseca (2002), centra-se na objetividade com resultados que podem ser mensurados por meio da utilização da linguagem matemática. Para os autores Miguel et al. (2012) é possível complementar e atualizar esta definição, pois segundo os mesmos, modelos quantitativos são os que se baseiam em modelagem matemática e computacional para calcular valores numéricos dos parâmetros do sistema em questão representando variáveis de desempenho de caráter físico ou econômico.

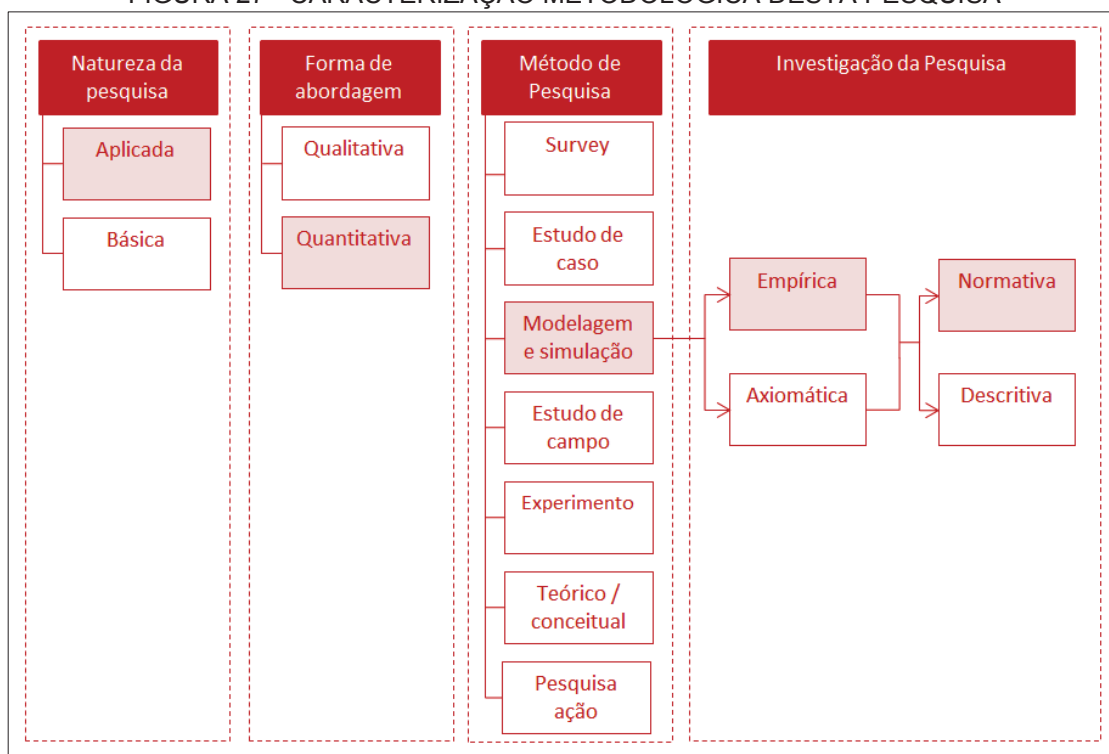
Esta pesquisa pode também ser classificada de acordo com o método empregado em seu desenvolvimento. Miguel et. al (2012) propõem sete categorias diferentes para esta classificação, sendo as mesmas mostradas na FIGURA 27. Este estudo enquadra-se como uma pesquisa de modelagem e simulação, que é caracterizado pelos referidos autores, pelo uso de técnicas matemáticas e ou experimentais (simulação) para descrever o funcionamento de um sistema e auxiliar no processo de tomada de decisão. Partindo do princípio de que é possível construir modelos que expressem o comportamento de processos reais e que as relações entre as variáveis sejam causais (onde é reconhecido que uma mudança em um valor de uma variável leva a mudança do valor de outra variável) pode-se perceber como

consequência, a obtenção não somente da explicação do fato/processo observado, mas também, a possibilidade de prever ou sugerir um estado futuro para o processo modelado.

Pesquisas baseadas no método de modelagem e simulação podem ainda ser classificadas de acordo com o tipo de investigação a ser realizada. Esta pesquisa tem características de investigação do tipo empírico normativa, definido pelos autores Miguel et al. (2012), como aqueles interessados na criação de modelos que se adequem bem às relações causais existentes no problema real, e normativos aqueles visando a melhoria da situação atual. Assim, uma pesquisa empírica normativa baseia-se em modelos que prescrevem uma solução e ou decisão para o problema real baseada em problemas de otimização matemática.

A FIGURA 27, conforme já mencionada, sintetiza a classificação metodológica descrita. Separada em quatro campos principais, sendo: natureza, forma de abordagem, método de pesquisa e maneira de investigação da pesquisa, é possível perceber o posicionamento desta pesquisa quanto a metodologia: é uma pesquisa de natureza aplicada, abordada de maneira quantitativa, pelo método de modelagem e simulação investigada de maneira empírica normativa.

FIGURA 27 - CARACTERIZAÇÃO METODOLÓGICA DESTA PESQUISA



FONTE: adaptado de Miguel et al. (2012)

4.2 ETAPAS DO PROCEDIMENTO METODOLÓGICO

De acordo com os autores Miguel et al. (2012), uma abordagem em cinco passos para a resolução de um problema sob a ótica da Pesquisa Operacional é proposta; a FIGURA 28 apresenta estes passos e os pontos relevantes de cada um deles.

FIGURA 28 - ABORDAGEM DA PESQUISA OPERACIONAL PARA RESOLUÇÃO DE PROBLEMAS

1. Definir o Problema	<ul style="list-style-type: none"> • Escopo do problema: objetivos, alternativas de decisão e limitações. • Construção do modelo conceitual;
2. Construir o Modelo	<ul style="list-style-type: none"> • Processo de Modelagem: construção do modelo matemático;
3. Solucionar o Modelo	<ul style="list-style-type: none"> • Definição do método: definição do(s) algoritmo(s) de resolução; • Implementação computacional;
4. Validar o Modelo	<ul style="list-style-type: none"> • Verificação do modelo proposto por meio de testes em instâncias da literatura e da solução obtida pela adequação da mesma ao caso real.
5. Propor a Solução	<ul style="list-style-type: none"> • Propor a empresa em questão a nova solução obtida.

FONTE: adaptado de Miguel et al. (2012)

As atividades desenvolvidas foram conduzidas de acordo com a metodologia de 5 passos proposta na FIGURA 28, sendo que tem-se como etapa “zero” o levantamento de informações da empresa de jornais em questão, em relação ao procedimento atualmente utilizado no processo de distribuição e entrega de jornais, para possibilitar as futuras comparações entre a situação atual e a proposta de nova solução.

A etapa 1 consiste na definição do problema e construção do modelo conceitual, que pode ser definido como a “tradução” da situação real encontrada na empresa ABC durante o processo de entrega dos jornais. Nesta fase, foi elaborado o modelo conceitual do problema das entregas de jornais, onde foram identificados os objetivos pretendidos pela empresa ABC, suas características e relacionamentos representando o processo observado. Relembrando, o objetivo pretendido pela empresa ABC é: minimizar as distâncias a serem percorridas pelos funcionários (entregadores) e equilibrar a quantidade de jornais entregues em cada uma das rotas a serem executadas.

Um dos fatores restritivos que se pode mencionar desta fase é a grande quantidade de clientes envolvidos no processo de atendimento do distribuidor da região Sul e a grande quantidade de roteiros diferentes atualmente utilizados. Mediante esse fato, algumas simplificações foram sugeridas como o uso dos macro pontos de demanda para representação do problema. As etapas 0 e 1 têm seus resultados apresentados no capítulo 2: DESCRIÇÃO DO PROBLEMA.

A etapa 2, a de construção do modelo matemático, foi realizada baseada no modelo conceitual construído na etapa 1. Em função das características da situação real, a condução da pesquisa foi baseada nos modelos matemáticos apresentados nas equações de (1) a (6) para o PFL e (12) a (16) para o PCVA.

A etapa 3 que se refere à definição do método de solução do modelo é explicada detalhadamente na seção 4.3: MÉTODO PROPOSTO PARA RESOLUÇÃO DO PROBLEMA, e faz uso de procedimentos heurísticos, entre os quais o algoritmo de Teitz & Bart, o algoritmo de Gillett e Johnson modificado e o algoritmo de Vogel, *First-Fit*, *First-Fit-Decreasing*, algoritmo dos *savings* de Clarke e Wright, algoritmos de inserção, e/ou meta-heurísticos como Algoritmo Genético e *Simulated Annealing*, os quais foram implementados na linguagem de programação R.


Na etapa 4, fase de verificação e validação, os programas computacionais elaborados na terceira etapa foram testados em instâncias de dados providas da literatura, comparados com resultados já conhecidos a fim de que os programas computacionais sejam considerados válidos para a resolução do problema real. Os resultados estão apresentados na seção 5.5: Instâncias da Literatura.

Como quinta e última etapa, a nova solução otimizada obtida foi comunicada e sugerida a empresa para otimização do processo de entregas de jornais para o roteiro em questão aqui analisado.

4.3 MÉTODO PROPOSTO PARA RESOLUÇÃO DO PROBLEMA

O método de resolução aplicado para obtenção das rotas otimizadas ao problema de roteamento de veículos em questão, consiste em uma abordagem em duas etapas, conforme apresentado na FIGURA 29. Primeiramente, o problema é sintetizado como um conjunto de clientes que correspondem aos pontos em vermelho, e um depósito de onde partem e para onde devem retornar os entregadores, representado em azul. A abordagem em duas etapas consiste em (1) definição de

agrupamentos entre os pontos de demanda por meio de técnicas do PLF e na sequência (2) definição dos roteiros a serem percorridos pelos entregadores, de forma a minimizar a distância, por meio de técnicas do PCV.



FONTE: A autora (2019).

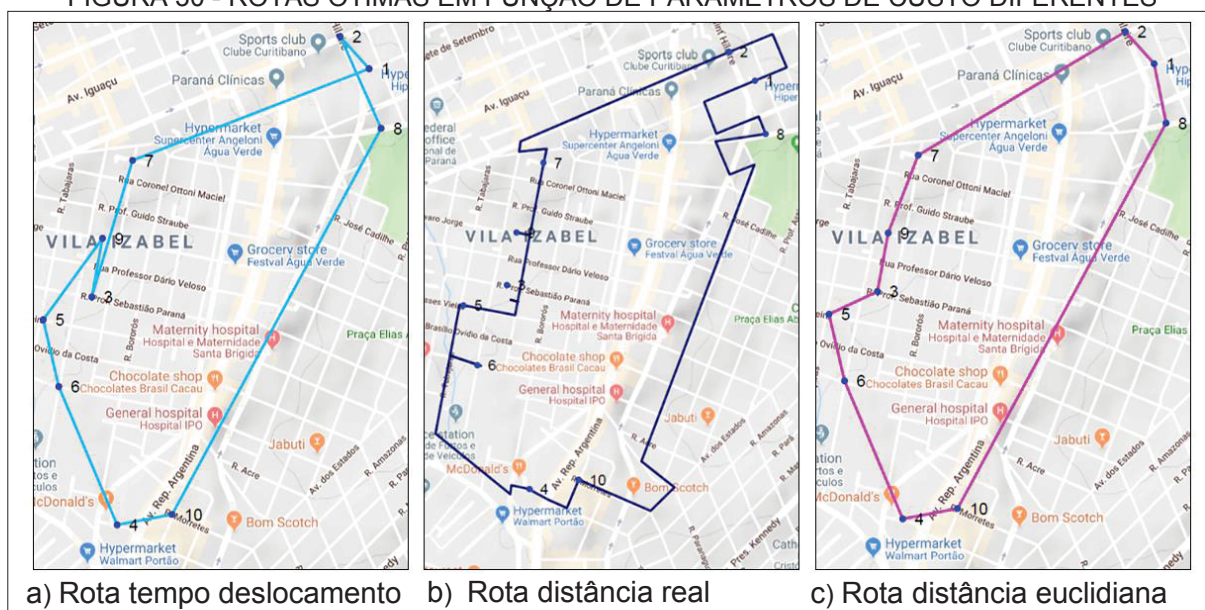
Para aplicação do PLF e do PCV é necessária a definição de uma forma de representação de custos a ser utilizada como base para a resolução. Estes custos podem se dar, por exemplo, em termos de distâncias ou tempos de deslocamento entre os pontos de demanda. No caso das distâncias, estas podem ser as distâncias reais ou distâncias estimadas, como por exemplo as distâncias Euclidianas. Para a definição da forma de representação de custo a ser utilizada como referência, duas informações foram levadas em conta: (1) objetivo da empresa ABC que visa uma diminuição na distância total percorrida pelos entregadores e (2) análise em um caso reduzido de pontos para formação de um roteiro, baseado em diferentes formas de custo para verificação dos impactos na resposta final.

A análise em caso reduzido foi realizada com os 10 primeiros macro pontos de demanda apresentados na TABELA 1 do capítulo 2. Realizou-se o levantamento de três matrizes de custos de dimensão 10x10: (1) tempos reais de deslocamento entre os pontos de demanda; (2) distâncias reais de deslocamento em função dos trajetos nas respectivas ruas de ligação entre os pontos e (3) distâncias euclidianas entre os pontos de demanda. As distâncias e os tempos reais de deslocamento foram levantados “par a par” por meio do site do *Google Maps*, enquanto que as distâncias Euclidianas foram calculadas em função das coordenadas dos 10 pontos (longitude / latitude) resultando em valores angulares, que foram então convertidos em quilômetros por meio de uma regra de 3 simples entre o raio da terra que tem

aproximadamente 6371km, onde 360° equivalem a 40030 km (obtidos pela aplicação da fórmula de comprimento da circunferência).

A partir destas três matrizes, por meio da aplicação do modelo matemático do PCV, a rota ótima foi obtida para cada cenário. A FIGURA 30 apresenta a ilustração destas três rotas ótimas obtidas, e a TABELA 4 apresenta as equivalências destas rotas em relação às outras bases de dados. É possível perceber assim que, em função do objetivo da empresa ABC de minimização do deslocamento dos entregadores, a melhor forma para compor a matriz de custos a ser utilizada no estudo de caso completo é a de distâncias reais de deslocamento que totaliza um deslocamento de 8,43km, uma vez que as demais formas, tempos reais e distâncias euclidianas, resultam em rotas ótimas correspondendo a maiores distâncias reais de deslocamento, com 9,33km e 9,08km respectivamente. Vale ressaltar que a fim de ilustrar as diferenças entre as bases de dados, a rota correspondente à forma das distâncias reais de deslocamento foi ilustrada na FIGURA 30 com o trajeto percorrendo as respectivas ruas. As demais rotas estão ilustradas com uma reta unindo os pontos de demanda sem levar em conta o percurso das ruas apenas para demonstração da sequência de atendimento aos pontos de demanda. Assim, em função da forma de custo definida como sendo as distâncias reais de deslocamento entre os pares de pontos de demanda, a matriz de deslocamentos para os 35 macro pontos foi construída e é apresentada no ANEXO 2.

FIGURA 30 - ROTAS ÓTIMAS EM FUNÇÃO DE PARÂMETROS DE CUSTO DIFERENTES



FONTE: A autora (2019).

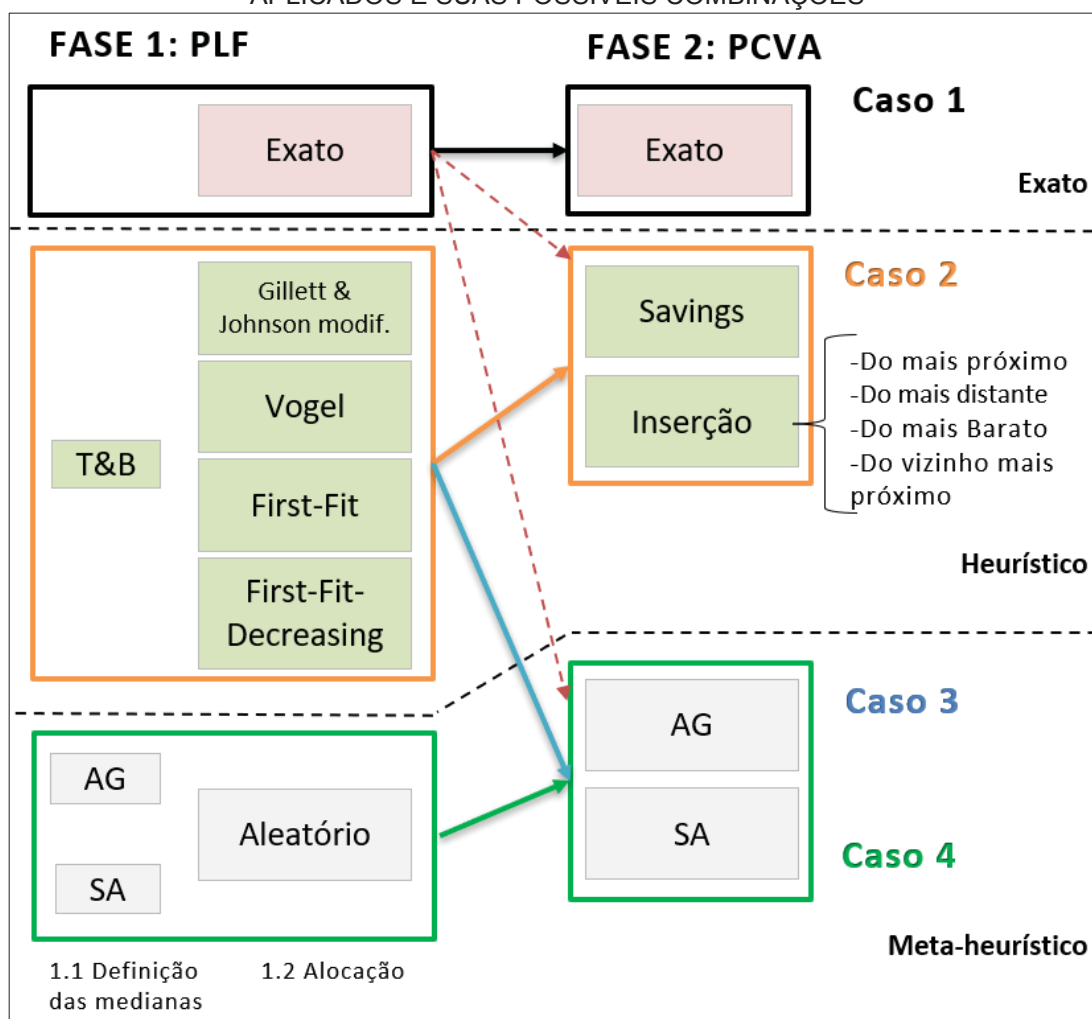
TABELA 4 - ROTAS ÓTIMAS EM RELAÇÃO AOS DIFERENTES PARÂMETROS BASE DE CUSTO

Rota exata com base em:	Valores correspondente		
	Tempo real (min)	Distância real (km)	Distância euclidiana (km)
Tempo real (min)	32	9,33	6,12
Distância real (km)	38	8,43	5,44
Distância euclidiana (km)	33	9,08	5,44

FONTE: A autora (2019).

Assim, com base na matriz de distâncias reais apresentadas no ANEXO 2, os procedimentos exatos, heurísticos e meta-heurísticos serão combinados em 4 casos, sendo: 1 - agrupamento exato (PLF) com roteamento exato (PCVA); 2 - agrupamento heurístico (PLF) com roteamento heurístico (PCVA); 3 - agrupamento heurístico (PLF) com roteamento meta-heurístico (PCVA) e 4 - agrupamento meta-heurístico (PLF) com roteamento meta-heurístico (PCVA). As combinações podem ser visualizadas na FIGURA 31, totalizando 40 maneiras de resolução diferentes para resolução do PRV.

FIGURA 31 - PROCEDIMENTOS EXATOS, HEURÍSTICOS E META-HEURÍSTICOS A SEREM APLICADOS E SUAS POSSÍVEIS COMBINAÇÕES



FONTE: A autora (2019).

Vale ressaltar que manteve-se o resultado obtido pela abordagem exata para o PLF e realizou-se a resolução do PCVA pelos métodos heurísticos e meta-heurísticos propostos, conforme indicado pelas setas tracejadas em vermelho na FIGURA 31. Estes resultados são apresentados conjuntamente com os casos 2 e 3. A seguir são detalhadas as especificidades de cada método utilizado.

4.4 ESPECIFICIDADES DOS PROCEDIMENTOS ADOTADOS

Os algoritmos Teitz & Bart (T&B), Gillett e Johnson modificado, Vogel, *Savings* de Clarke & Wright e métodos de inserção foram implementados seguindo a descrição das seções 3.3.2.2. e 3.3.3.2. Para os demais métodos empregados, são apresentadas as especificidades de sua implementação computacional.

Para os métodos meta-heurísticos AG e AS, os parâmetros apresentados detalhadamente nas seções de 4.4.2 à 4.4.5 foram definidos em função de testes realizados na base de dados entre variações de combinações de parâmetros, sendo selecionada a de melhor desempenho em termos de tempo de processamento e qualidade de solução.

4.4.1 *First-Fit* e *First-Fit-Decreasing*

A especificidade incluída neste algoritmo, em relação ao apresentado na seção 3.3.2.2 itens D e E, é a inclusão da condição de mínima distância, ou seja, o ponto de demanda em questão é alocado à mediana que tenha capacidade disponível e que seja a mais próxima ao ponto a ser alocado (ou seja, não apenas a primeira mediana que tenha capacidade disponível como os algoritmos sugerem). A condição de respeitar a distância mínima foi incluída uma vez que os algoritmos *First-Fit* e *First-Fit-Decreasing* apresentaram melhores resultados em termos de menor distância total para o PLF do que sem esta condição.

4.4.2 Algoritmo genético para o PLF

Os parâmetros utilizados para o AG, para o PLF foram: tamanho da população = 100, número de gerações = 100, probabilidade de mutação = 1%. A população inicial foi criada pelo sorteio aleatório de p medianas seguidas da função alocação.

A função alocação é descrita por: designação em ordem aleatória dos demais pontos às medianas sorteadas, sendo sempre cada ponto alocado à mediana mais próxima de sua localização que ainda disponha capacidade. Devido a obtenção de respostas infactíveis, fez-se necessário priorizar a alocação de 40% dos vértices de maior demanda à sua mediana mais próxima.

- Seleção: método da roleta para selecionar dois pais, onde a probabilidade da escolha é proporcional ao valor da Função Objetivo (*fitness*) calculada em relação à alocação.
- Cruzamento e mutação: a partir dos dois indivíduos pais selecionados, foi realizada a troca aleatória de medianas entre os dois e depois realocação dos vértices de acordo com a função alocação. Dois indivíduos filhos foram gerados para cada seleção de pais até que a população fosse reconstituída. Em relação a mutação, foi efetuada a troca de uma mediana por um vértice não mediana, ambos aleatoriamente selecionados, e realocação dos vértices ao novo conjunto de medianas.
- Composição da nova população: a cada iteração, foram criados indivíduos filhos até que o parâmetro tamanho da população fosse atingido. Uma vez unidas população inicial e novos indivíduos, foram mantidos para próxima geração somente os melhores cromossomos até o momento, em função do menor *fitness*.

Adicionalmente, dois algoritmos de busca local foram aplicados para aperfeiçoamento das soluções encontradas pelo algoritmo principal. A primeira busca local prevê a troca de clientes entre agrupamentos em caso de minimização da distância total de deslocamento uma vez que se mantenha o respeito à condição de capacidade total em cada um dos grupos. A segunda busca local verifica a possibilidade de substituição da mediana de um agrupamento por algum dos pontos de demanda a ela alocado, novamente em caso de minimização da distância total a troca é efetivada. As buscas locais foram aplicadas ao indivíduo de melhor *fitness* de cada geração, buscando aprimorar as soluções obtidas.

4.4.3 Algoritmo genético para o PCVA

Os parâmetros utilizados para o AG, para o PCVA foram: tamanho da população = 100, número de gerações = 100, probabilidade de mutação = variável em função desvio padrão dos valores do *fitness* de cada cromossomo. A probabilidade de mutação inicial foi fixada em 1%. Caso o desvio padrão do *fitness* da população obtida ficasse menor do que 5, a probabilidade de mutação na próxima iteração é alterada para 80% visando aumentar a variabilidade das soluções obtidas.

Cada indivíduo da população inicial foi criado pela heurística de inserção do vizinho mais próximo, com ponto inicial escolhido aleatoriamente, seguido do procedimento de refinamento de rotas 2-*opt*.

- Seleção: igualmente ao descrito no AG para o PLF, utilizou-se o método da roleta para seleção dos indivíduos pais.
- Cruzamento e mutação: *crossover* de um ponto (escolha aleatória do ponto de cruzamento para fragmentar tanto o pai 1 quanto o pai 2 e então recombinar as “partes” para a criação de novos indivíduos). Um mecanismo de reparação foi adicionado, ou seja, em caso de repetição de algum ponto da rota no novo cromossomo, este ponto é substituído pelo ponto que esteja fora da rota. Foram gerados dois filhos a cada seleção. Para mutação, foi utilizada a mutação baseada em ordem, onde 2 posições do cromossomo (i e j) são selecionadas aleatoriamente e troca-se o elemento da posição i com o da j . Os cromossomos obtidos tanto pelo operador de *crossover* quanto de mutação foram seguidos de refinamento pela busca local 2-*opt* para melhora da qualidade de solução.
- Composição da nova população: igualmente ao descrito no AG para o PLF, foram mantidos para próxima geração somente os melhores cromossomos até o momento, em função do menor *fitness*.

4.4.4 *Simulated Annealing* para o PLF

O algoritmo implementado segue o descrito na seção 3.3.4.2 e os parâmetros utilizados no SA para o PLF foram: número de iterações a cada dada temperatura = 250, número de soluções iniciais = 1000; a temperatura inicial a cada rodada é dada por: $T_0 = \ln(f(s))$ e taxa de resfriamento $\alpha=0,95$.

As soluções iniciais foram obtidas de acordo com o sorteio de um conjunto de p vértices para mediana, seguidos da alocação dos vértices restantes pela função alocação que é descrita no Algoritmo Genético para o PLF. Assim, dentre todas

soluções geradas, aquela que apresentou melhor valor de *fitness* foi selecionada como solução inicial para o SA.

Para obtenção de novas soluções, a vizinhança utilizada foi a troca aleatória de um dos elementos do conjunto medianas por um dos demais vértices, seguida da alocação dos vértices ao novo conjunto mediana.

4.4.5 *Simulated Annealing* para o PCVA

O algoritmo implementado segue o descrito na seção 3.3.4.2 e os parâmetros utilizados no SA para o PCVA foram: número de iterações a cada dada temperatura = 250, número de soluções iniciais = 10; a temperatura inicial a cada rodada é dada por: $T_0 = \ln(f(s))$ e taxa de resfriamento $\alpha=0,95$ para casos de até 100 pontos e de $\alpha=0,99$ para casos com mais de 100 pontos.

Para o PCVA as soluções iniciais foram obtidas pela heurística de inserção do vizinho mais próximo, com ponto inicial escolhido aleatoriamente, seguido do procedimento de refinamento de rotas 2-*opt*. De maneira semelhante ao descrito para o PLF, dentre todas as soluções iniciais a com melhor valor de *fitness* foi selecionada como solução inicial para o SA.

Para obtenção de novas soluções a vizinhança utilizada foi o *swap* de dois pontos (escolha aleatória de duas posições e troca dos vértices destas posições) seguido da busca local de refinamento de rotas 2-*opt*.

No capítulo seguinte são apresentados os resultados obtidos para as instâncias da literatura do PLF e do PCVA e para o estudo de caso, baseados nos procedimentos aqui detalhados.

5 RESULTADOS

Este capítulo apresenta os resultados para as diferentes abordagens de resolução propostas, sendo: I - Agrupamento exato com roteamento exato, II - Agrupamento heurístico com roteamento heurístico, III - Agrupamento heurístico com roteamento meta-heurístico e IV - Agrupamento meta-heurístico com roteamento meta-heurístico. Também são apresentados os resultados em relação às instâncias da literatura tanto para o PLF quanto para o PCV bem como a análise dos mesmos.

Optou-se por ilustrar as rotas obtidas e apresentar a sequência de resultados para cada uma delas apenas na abordagem I (exata) e na que corresponde ao menor valor total de deslocamento total abordagem IV, a fim de esclarecer ao leitor o que elas representam. Assim, para as demais abordagens apenas serão apresentados os valores de deslocamento total obtidos (somatório das distâncias de cada uma das 5 rotas), uma vez que o objetivo das demais abordagens é verificar a diferença de qualidade de solução entre os diferentes métodos.

Os resultados da abordagem exata para o PLF e o PCVA foram obtidos por meio do *software* LINGO 12.0 (*Language for Interactive Optimizer Systems*) e os resultados para os procedimentos heurísticos e meta-heurísticos para o PLF e o PCVA foram obtidos por meio de programas computacionais desenvolvidos na linguagem de programação R, utilizando o R-Studio versão 3.5.2 (2018-12-20). Para os experimentos foi utilizado um notebook com processador Intel(R) Core(TM) i5-5200U CPU 2.20GHz, 8GB de RAM e 64 bits.

5.1 ABORDAGEM I – AGRUPAMENTO EXATO (PLF) COM ROTEAMENTO EXATO (PCVA)

Os resultados da abordagem exata para o PLF e PCVA em duas etapas foram obtidos por meio da resolução dos respectivos modelos de PLIB apresentados, considerando-se os 35 macro pontos apresentados na TABELA 1 e a respectiva matriz de distâncias apresentada no ANEXO 2.

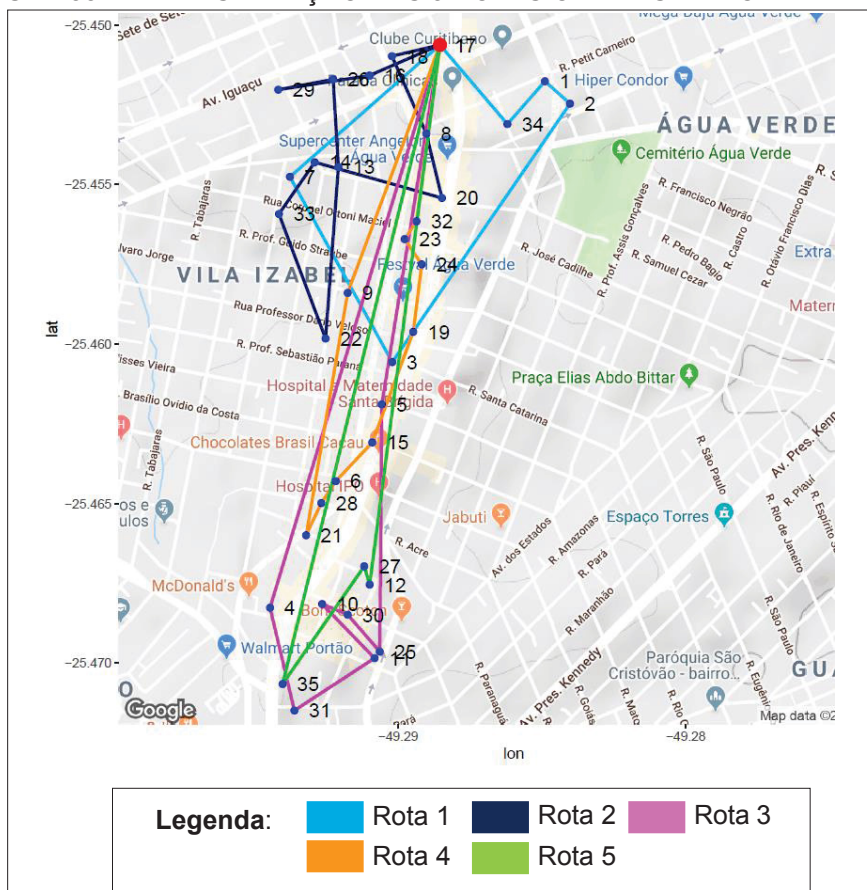
Em relação a resolução do PLF capacitado, para divisão dos pontos de demanda em grupos menores, a FIGURA 32 apresenta graficamente a proposta de agrupamento que minimiza a distância de cada ponto a sua respectiva mediana bem

TABELA 5 - DADOS DAS 5 ROTAS OTIMIZADAS OBTIDAS PELA ABORDAGEM I

Roteiro	Sequência	Capacidade utilizada	Deslocamento (km)
Rota 1	0-7-3-2-1-34-0	98	5,54
Rota 2	0-17-18-8-20-14-33-22-13-26-29-16-0	100	5,25
Rota 3	0-4-31-11-10-30-25-5-0	83	7,41
Rota 4	0-32-23-24-19-15-6-28-21-9-0	100	5,48
Rota 5	0-35-27-12-0	98	6,81
Total		479	30,49

FONTE: A autora (2019).

FIGURA 33 - REPRESENTAÇÃO DAS 5 ROTAS OBTIDAS DE FORMA EXATA



FONTE: A autora (2019).

5.2 ABORDAGEM II - AGRUPAMENTO HEURÍSTICO (PLF) COM ROTEAMENTO HEURÍSTICO (PCVA)

Em relação aos procedimentos heurísticos empregados para resolução do PFL, tem-se na TABELA 6 uma classificação por meio de esquema de cores (melhor valor obtido= verde, pior valor obtido= vermelho) dos diferentes valores da FO do PLF (conforme equação 1) para os respectivos agrupamentos obtidos por cada método. A coluna referência será usada posteriormente para designar o respectivo método de agrupamento utilizado (o nome do método é apresentado na coluna Método de

Agrupamento). A fim de comparação, manteve-se nesta tabela o valor da FO do PLF obtida pelo método exato já apresentada na seção 5.1.

TABELA 6 - VALORES DE FO PARA O PLF OBTIDOS PELOS DIFERENTES MÉTODOS HEURÍSTICOS DE AGRUPAMENTO

Ref.	Método de Agrupamento	FO do PLF (km)	Tempo execução (s)
A	Agrupamento exato (PLF)	163,78	2
B	T&B + G&J Modificado	214,36	2,15
C	T&B + VOGEL	227,36	1,63
D	T&B + FF (min. distância)	229,82	0,73
E	T&B + FFD (min. distância)	228,14	0,76

FONTE: A autora (2019).

Assim, uma vez conhecidos os macro pontos pertencentes a cada grupo, cinco procedimentos de construção de rotas heurísticos foram empregados para definição dos respectivos roteiros de entrega do motoboy, sendo 1: *Savings*, 2: Inserção do mais próximo, 3: Inserção do mais distante, 4: Inserção do mais barato e 5: Inserção do vizinho mais próximo. Os valores totais do deslocamento em quilômetros do motoboy para cada uma das técnicas citadas estão apresentados na TABELA 7. Cada método heurístico de roteamento corresponde a uma das colunas numeradas da TABELA 7, onde conjuntamente está apresentado o tempo de processamento computacional em segundos para se obter o resultado. Na coluna Ref. estão indicados os métodos de agrupamentos conforme descrição da TABELA 6, que definiu os grupos sobre os quais se aplicou os procedimentos heurísticos de roteamento.

TABELA 7 - DISTÂNCIA TOTAL DE DESLOCAMENTO PARA ENTREGAS OBTIDA POR MÉTODOS HEURÍSTICOS EM FUNÇÃO DOS DIFERENTES MÉTODOS DE AGRUPAMENTO

Ref.	1 (km)	T (s)	2 (km)	T (s)	3 (km)	T (s)	4 (km)	T (s)	5 (km)	T (s)
A	32,39	1,84	31,58	0,28	31,69	0,29	31,28	0,30	32,87	0,30
B	29,59	1,23	29,65	0,28	31,02	0,3	29,65	0,30	32,11	0,33
C	30,14	1,26	29,75	0,36	30,64	0,3	29,75	0,31	30,75	0,32
D	33,19	1,53	30,72	0,30	32,44	0,28	30,72	0,28	33,12	0,31
E	34,09	1,28	33,14	0,44	33,19	0,3	33,29	0,34	35,6	0,31

FONTE: A autora (2019).

LEGENDA: 1: *Savings*, 2: Inserção do mais próximo, 3: Inserção do mais distante, 4: Inserção do mais barato e 5: Inserção do vizinho mais próximo; A a E: conforme indicados na Tabela 6.

5.3 ABORDAGEM III - AGRUPAMENTO HEURÍSTICO (PLF) COM ROTEAMENTO META-HEURÍSTICO (PCVA)

Em função dos agrupamentos obtidos de maneira heurística também foi executado o roteamento por dois métodos meta-heurísticos sendo (1) Algoritmo Genético e (2) *Simulated Annealing*. Os valores totais do deslocamento em quilômetros do motoboy para cada uma das técnicas meta-heurísticas citadas são apresentados na TABELA 8. O tempo computacional necessário para o processamento de cada um dos conjuntos é apresentado na coluna T (s).

TABELA 8 - DISTÂNCIA TOTAL DE DESLOCAMENTO PARA ENTREGAS OBTIDA POR MÉTODOS META-HEURÍSTICOS EM FUNÇÃO DOS DIFERENTES MÉTODOS DE AGRUPAMENTO

Ref.	Método de Agrupamento	Ref.	Algoritmo Genético (km)	T (s)	<i>Simulated Annealing</i> (km)	T (s)
A	Agrupamento exato (PLF)	A	30,49	4,76	30,49	8,15
B	T&B + G&J Modificado	B	29,25	4,97	29,25	8,03
C	T&B + VOGEL	C	29,35	4,81	29,35	7,44
D	T&B + FF (min. distância)	D	30,72	4,73	30,72	8,18
E	T&B + FFD (min. distância)	E	32,24	4,91	32,24	7,77

FONTE: A autora (2019).

5.4 ABORDAGEM IV - AGRUPAMENTO META-HEURÍSTICO (PLF) COM ROTEAMENTO META-HEURÍSTICO (PCVA)

Dois procedimentos meta-heurísticos foram utilizados para resolução do PLF, sendo o Algoritmo Genético e o *Simulated Annealing*. Os resultados para cada um deles são apresentados na TABELA 9, sendo o valor da FO do PLF descrita na equação (1) e o tempo computacional para execução computacional de cada um dos métodos.

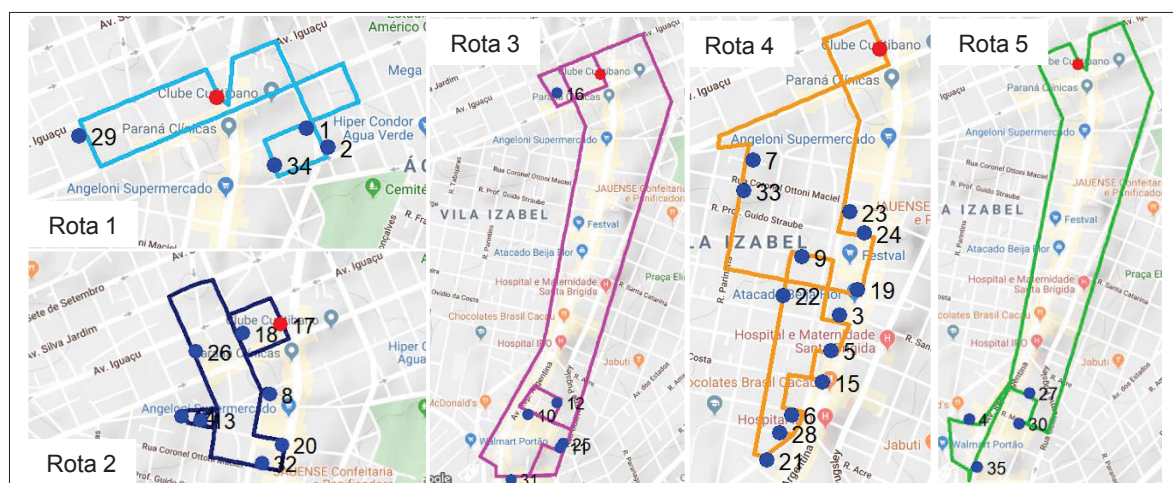
TABELA 9 - VALORES DE FO PARA O PLF OBTIDOS PELOS MÉTODOS META-HEURÍSTICOS DE AGRUPAMENTO

Método Agrupamento	FO do PLF (km)	Tempo execução (s)
Algoritmo Genético	166,74	5,49
<i>Simulated Annealing</i>	167,74	6,09

FONTE: A autora (2019).

A partir dos grupos definidos em cada um dos métodos do PLF foi executada a resolução da segunda etapa, o roteamento pelo PCV, também pelos métodos meta-

FIGURA 35 - REPRESENTAÇÃO DOS DESLOCAMENTOS REAIS DE CADA ROTA OBTIDA PELO ALGORITMO GENÉTICO



FONTE: A autora (2019).

É importante destacar que a abordagem exata utilizada na seção 5.1 para obtenção das rotas que resultou em uma distância total de 30,49 km, considera o uso dos modelos matemáticos do PLF seguido do PCV em duas etapas sequenciais. Devido a este motivo é possível perceber que algumas combinações de métodos heurísticos e meta-heurísticos tiveram um resultado melhor que a abordagem exata considerada.

5.5 INSTÂNCIAS DA LITERATURA

Nesta seção são apresentados os resultados e as considerações sobre os testes computacionais aplicados às técnicas relacionadas ao PLF e ao PCVA usadas na resolução do estudo de caso a fim de verificação dos algoritmos propostos para resolução do estudo de caso.

5.5.1 Instâncias da Literatura aplicado aos algoritmos de resolução do PLF

Para o PLF capacitado as instâncias consideradas correspondem a dois conjuntos diferentes de problemas. O primeiro conjunto proposto por Osman e Christofides (1994) disponível em <http://people.brunel.ac.uk/~mastijb/jeb/orlib/files/>, compreende 20 problemas teste, variando de 50 a 100 vértices enquanto as medianas a serem definidas variam de 5 a 10. O segundo conjunto de instâncias, contém 6 problemas que representam dados reais da área central da cidade de São José dos

Campos, com diferentes quantidades de vértices e medianas a serem escolhidas (100 x 10), (200 x 15), (300 x 25), (300 x 30), (402 x 30) e (402 x 40) e foi selecionado como segundo conjunto e instâncias de teste para verificar o desempenho dos métodos propostos em casos com maior quantidade de vértices e medianas. As informações estão disponíveis em <http://www.lac.inpe.br/~lorena/instancias.html>.

A TABELA 11 apresenta os resultados detalhados obtidos em cada instância de teste para cada um dos métodos propostos, sendo que nos cinco primeiros métodos considerou-se a resolução da primeira etapa pelo algoritmo de Teitz & Bart seguido dos métodos de Gillett e Johnson modificado, Vogel, *First-Fit* (FF), *First-Fit-Decreasing* (FFD) respectivamente. E nos dois últimos experimentos considerou-se separadamente o Algoritmo Genético e *Simulated Annealing*. Inicialmente na tabela têm-se o nome de cada instância, número de vértices (n), número de medianas a ser localizado (p), a capacidade individual de cada mediana e o resultado ótimo. Na sequência são apresentados para cada um dos métodos os respectivos valores obtidos de Melhor valor para FO, Erro percentual (obtido por meio da divisão do valor obtido pelo método para FO e do valor ótimo da respectiva instância), e por fim o tempo computacional de execução em segundos.

TABELA 11 - RESULTADO DAS TÉCNICAS RELACIONADAS AO PLF CAPACITADO PARA AS INSTÂNCIAS DA LITERATURA

(continua)

MÉTODO:				T&B + G&J Modificado			T&B + VOGEL			T&B + FF (min. distância)			
Instância	Vértices (n)	Medianas (p)	Capacidade individual	Ótimo	Melhor	Erro (%)	Tempo exc. (s)	Melhor	Erro (%)	Tempo exc. (s)	Melhor	Erro (%)	Tempo exc. (s)
cpmp01	50	5	120	713	726	1,82	0,09	726	1,82	0,14	748	4,91	0,06
cpmp02	50	5	120	740	831	5,59	0,11	845	14,19	0,13	846	14,32	0,08
cpmp03	50	5	120	751	688	5,68	0,08	840	11,85	0,13	940	25,17	0,08
cpmp04	50	5	120	651	713	7,38	0,08	725	11,37	0,14	689	5,84	0,09
cpmp05	50	5	120	664	1038	7,45	2,31	688	3,61	0,13	743	11,90	0,08
cpmp06	50	5	120	778	1026	7,55	2,02	952	22,37	0,17	998	28,28	0,08
cpmp07	50	5	120	787	885	7,93	0,08	837	6,35	0,18	890	13,09	0,08
cpmp08	50	5	120	820	1062	8,15	1,42	891	8,66	0,14	909	10,85	0,09
cpmp09	50	5	120	715	775	8,39	0,10	762	6,57	0,13	780	9,09	0,10
cpmp10	50	5	120	829	1094	8,75	1,65	944	13,87	0,09	987	19,06	0,07
cpmp11	100	10	120	1006	1116	8,77	2,00	1123	11,63	1,78	1133	12,62	1,27
cpmp12	100	10	120	966	1122	8,83	1,96	1038	7,45	2,2	1103	14,18	1,62
cpmp13	100	10	120	1026	907	9,41	0,08	1144	11,50	1,99	1116	8,77	1,75
cpmp14	100	10	120	982	822	9,45	0,09	1099	11,91	2,09	1135	15,58	2,00
cpmp15	100	10	120	1091	1142	9,49	1,68	1196	9,62	1,71	1251	14,67	1,46
cpmp16	100	10	120	954	1196	9,62	1,61	1044	9,43	1,97	1067	11,84	1,74
cpmp17	100	10	120	1034	816	10,27	0,07	1160	12,19	2,04	1192	15,28	1,82
cpmp18	100	10	120	1043	1162	12,38	1,92	1159	11,12	1,8	1206	15,63	1,41
cpmp19	100	10	120	1031	1164	15,82	1,83	1178	14,26	3,29	1166	13,09	1,76
cpmp20	100	10	120	1005	951	22,24	0,08	1258	25,17	2,79	1266	25,97	1,59
SJC1	100	10	720	17289	19272	11,47	1,32	19612	13,44	1,74	20286	17,33	1,72
SJC2	200	15	840	33271	36080	8,44	16,13	37702	13,32	20,36	37001	11,21	18,08
SJC3a	300	25	740	45335	51424	13,43	121,67	62541	37,95	160,15	51608	13,84	127,57
SJC3b	300	30	740	40636	46329	14,01	173,75	62333	53,39	170,36	45856	12,85	181,90
SJC4a	402	30	840	61926	70751	14,25	494,58	92088	48,71	348,95	71132	14,87	390,92
SJC4b	402	40	840	52470	61091	16,43	694,21	95313	81,65	747,73	61786	17,75	660,16

(conclusão)

MÉTODO:					T&B + FFD (min. distância)			Algoritmo Genético			Simulated Annealing		
Instância	Pontos (n)	Medianas (p)	Capacidade individual	Ótimo	Melhor	Erro (%)	Tempo exc. (s)	Melhor	Erro (%)	Tempo exc. (s)	Melhor	Erro (%)	Tempo exc. (s)
cmp01	50	5	120	713	761	6,73	0,10	726	1,82	6,11	726	1,82	19,44
cmp02	50	5	120	740	937	26,62	0,07	756	2,16	6,49	756	2,16	18,12
cmp03	50	5	120	751	1010	34,49	0,08	764	1,73	6,28	764	1,73	19,81
cmp04	50	5	120	651	764	17,36	0,06	665	2,15	6,49	666	2,30	19,8
cmp05	50	5	120	664	700	5,42	0,08	677	1,96	7,75	677	1,96	18,08
cmp06	50	5	120	778	1044	34,19	0,03	797	2,44	5,82	797	2,44	18,22
cmp07	50	5	120	787	920	16,90	0,06	815	3,56	5,67	819	4,07	18,1
cmp08	50	5	120	820	1090	32,93	0,09	837	2,07	5,68	837	2,07	18,56
cmp09	50	5	120	715	806	12,73	0,09	729	1,96	5,93	729	1,96	18,29
cmp10	50	5	120	829	1086	31,00	0,08	858	3,50	5,53	858	3,50	18,14
cmp11	100	10	120	1006	1134	12,72	1,52	1032	2,58	8,98	1038	3,18	26,97
cmp12	100	10	120	966	1145	18,53	1,72	991	2,59	9,06	991	2,59	26,12
cmp13	100	10	120	1026	1179	14,91	1,57	1051	2,44	10,86	1051	2,44	25,64
cmp14	100	10	120	982	1136	15,68	1,51	1007	2,55	21,61	1014	3,26	25,99
cmp15	100	10	120	1091	1382	26,67	1,50	1127	3,30	24,99	1132	3,76	25,99
cmp16	100	10	120	954	1057	10,80	1,62	980	2,73	10,02	979	2,62	26,09
cmp17	100	10	120	1034	1247	20,60	1,87	1058	2,32	9,99	1067	3,19	25,81
cmp18	100	10	120	1043	1249	19,75	1,57	1068	2,40	13,78	1076	3,16	26,08
cmp19	100	10	120	1031	1394	35,21	2,20	1058	2,62	11,97	1058	2,62	27,88
cmp20	100	10	120	1005	1700	69,15	1,83	1073	6,77	23,5	1088	8,26	28,55
SJC1	100	10	720	17289	19875	14,96	1,37	17389	0,58	9,03	17428	0,80	28,61
SJC2	200	15	840	33271	37201	11,81	20,19	33452	0,54	27,38	33544	0,82	54,27
SJC3a	300	25	740	45335	51865	14,40	126,25	45707	0,82	44,6	45702	0,81	72,53
SJC3b	300	30	740	40636	46329	14,01	192,24	41436	1,97	50,11	41007	0,91	77,47
SJC4a	402	30	840	61926	71047	14,73	405,51	63376	2,34	71,99	62583	1,06	94,07
SJC4b	402	40	840	52470	61838	17,85	790,95	53671	2,29	60,77	53326	1,63	100,53

FONTE: A autora (2019).

5.5.2 Instâncias da Literatura aplicado aos algoritmos de resolução do PCVA

As instâncias utilizadas para os testes dos algoritmos empregados na resolução do PCV assimétrico correspondem a 19 problemas da TSPLIB, variando de 17 até 443 vértices, disponíveis em <http://elib.zib.de/pub/mp-testdata/tsp/tsplib/atsp/index.html>. Esta base de instâncias foi selecionada, pois o estudo de caso também corresponde a um PCV assimétrico.

A TABELA 12 apresenta os resultados obtidos pela resolução do PCVA considerando-se os seguintes métodos heurísticos: dos *Savings* (economias) de Clarke e Wright (C&W), Inserção do Mais Próximo, Inserção do Mais Distante, Inserção do Mais Barato, Inserção do vizinho mais próximo. E dois métodos meta-heurísticos: Algoritmo Genético e *Simulated Annealing*.

TABELA 12 - RESULTADO DAS TÉCNICAS RELACIONADAS AO PCVA PARA AS INSTÂNCIAS DA LITERATURA

(continua)

MÉTODO:				SAVINGS C&W			INSER.DO + PRÓXIMO			INSER. DO + DISTANTE			INSER.DO + BARATO		
Número	Instância	Pontos	Ótimo	Melhor	Erro (%)	Tempo (s)	Melhor	Erro (%)	Tempo (s)	Melhor	Erro (%)	Tempo (s)	Melhor	Erro (%)	Tempo (s)
1	br17	17	39	40	2,56	0,01	39	0	0,01	39	0	0	39	0	0
2	ftv33	34	1286	1374	6,84	0,17	1433	11,43	0	1286	0	0	1441	12,05	0
3	ftv35	36	1473	1561	5,97	0,18	1578	7,13	0	1533	4,07	0	1548	5,09	0
4	ftv38	39	1530	1619	5,82	0,28	1635	6,86	0	1590	3,92	0	1665	8,82	0
5	p43	43	5620	5630	0,18	0,54	5638	0,32	0	5630	0,18	0	5633	0,23	0,02
6	ftv44	45	1613	1711	6,08	0,68	1776	10,11	0	1666	3,29	0	1745	8,18	0,01
7	ftv47	48	1776	1940	9,23	1	1940	9,23	0	1820	2,48	0,01	1846	3,94	0
8	ry48p	48	14422	15048	4,34	0,47	15394	6,74	0,01	14838	2,88	0	15184	5,28	0
9	ft53	53	6905	7688	11,34	0,7	7466	8,12	0,02	7316	5,95	0,01	7900	14,41	0
10	ftv55	56	1608	1772	10,20	0,78	1755	9,14	0,02	1676	4,23	0,01	1821	13,25	0,02
11	ftv64	65	1839	1991	8,27	2,25	2034	10,60	0,02	1988	8,10	0,04	2014	9,52	0,02
12	ft70	70	38673	40037	3,53	2,06	41020	6,07	0,01	40665	5,15	0	40684	5,20	0
13	ftv70	71	1950	2183	11,95	1,83	2151	10,31	0,02	2047	4,97	0,01	2209	13,28	0,01
14	kro124p	100	36230	39850	9,99	6,23	41098	13,44	0,03	38426	6,06	0,03	40964	13,07	0,01
15	ftv170	171	2755	3327	20,76	36,63	3318	20,44	0,11	3009	9,22	0,22	3732	35,46	0,03
16	rbg323	323	1326	1363	2,79	413,31	1510	13,88	0,61	1755	32,35	0,58	1582	19,31	0,19
17	rbg358	358	1163	1183	1,72	573,4	1388	19,35	0,78	1471	26,48	0,82	1485	27,69	0,25
18	rbg403	403	2465	2501	1,46	1243,72	2583	4,79	1,24	2611	5,92	1,42	2586	4,91	0,35
19	rbg443	443	2720	2765	1,65	1510,91	2859	5,11	1,66	2884	6,03	1,64	2866	5,37	0,42

(conclusão)

MÉTODOS				INSER.DO VIZ. + PROX.			ALGORITMO GENÉTICO			SIMULATED ANNEALING		
Número	Instância	Pontos	Ótimo	FO	Erro (%)	Tempo exc. (s)	FO	Erro (%)	Tempo exc. (s)	FO	Erro (%)	Tempo exc. (s)
1	br17	17	39	39	0	0	39	0	4,52	39	0	9,19
2	ftv33	34	1286	1491	15,94	0	1286	0	4,98	1286	0	12,99
3	ftv35	36	1473	1765	19,82	0	1473	0	4,89	1475	0,14	13,43
4	ftv38	39	1530	1863	21,76	0	1530	0	5,27	1530	0	13,64
5	p43	43	5620	5669	0,87	0	5620	0	6,72	5620	0	14,51
6	ftv44	45	1613	1825	13,14	0	1627	0,87	5,59	1648	2,17	18,33
7	ftv47	48	1776	2124	19,59	0	1921	8,16	5,86	1784	0,45	16,91
8	ry48p	48	14422	15368	6,56	0	14429	0,05	5,89	14446	0,17	17,59
9	ft53	53	6905	9084	31,56	0	7171	3,85	21,89	7179	3,97	27,3
10	ftv55	56	1608	1931	20,09	0	1691	5,16	23,21	1632	1,49	19,1
11	ftv64	65	1839	2227	21,10	0	1890	2,77	25,5	1915	4,13	21,47
12	ft70	70	38673	42270	9,30	0	40086	3,65	26,31	39736	2,75	24
13	ftv70	71	1950	2417	23,95	0	2025	3,85	27,29	1993	2,21	22,02
14	kro124p	100	36230	42460	17,20	0	37382	3,18	38,07	36653	1,17	28,06
15	ftv170	171	2755	3399	23,38	0	3038	10,27	149,79	2989	8,49	431,41
16	rbg323	323	1326	1778	34,09	0	1576	18,85	463,36	1507	13,65	679,76
17	rbg358	358	1163	1525	31,13	0,02	1370	17,80	643,56	1418	21,93	762,19
18	rbg403	403	2465	2741	11,20	0,01	2513	1,95	696,01	2584	4,83	935,19
19	rbg443	443	2720	3034	11,54	0,02	2804	3,09	845,63	2895	6,43	1122,66

FONTE: A autora (2019).


5.6 ANÁLISE DOS RESULTADOS

A seguir, são feitas as análises dos resultados obtidos em relação ao estudo de caso para entrega de jornais e nas Instâncias da Literatura.

5.6.1 Em relação ao estudo de caso para entrega dos jornais

Foram testadas 40 combinações de métodos para resolução em duas etapas do PRV do estudo de caso para entrega dos jornais da empresa ABC. O GRÁFICO 7 demonstra a relação entre valores normalizados de tempo computacional gasto por cada combinação de método e de distância total obtida pelo respectivo método. É possível perceber que os melhores métodos em termos de minimização da distância necessitaram de um maior tempo de processamento computacional (parte mais a direita do gráfico) enquanto os métodos que tiveram um tempo mais curto de execução obtiveram respostas de maior distância total (parte mais à esquerda do gráfico).

GRÁFICO 7 - RELAÇÃO ENTRE DISTÂNCIA TOTAL E TEMPO DE PROCESSAMENTO PARA CADA MÉTODO DE RESOLUÇÃO



LEGENDA: A a E Métodos do PLF, A: Agrupamento exato, B: T&B + G&J Modificado, C: T&B + VOGEL, D: T&B + FF (min. distância), E: T&B + FFD (min. distância). 1 a 5 Métodos do PCV, 1: Savings, 2: Inserção do mais próximo, 3: Inserção do mais distante, 4: Inserção do mais barato e 5: Inserção do vizinho mais próximo;

FONTE: A autora (2019).

O melhor valor obtido para minimizar o deslocamento total do entregador considerando-se as 40 combinações de métodos diferentes, representa uma distância real de trajeto de 27,04 km, com tempo computacional de 10,56 segundos para as duas etapas e foi obtido pelo emprego da técnica do Algoritmo Genético para

resolução do PLF seguida de roteirização por meio do Algoritmo Genético. Cita-se também que se considerando a roteirização por *Simulated Annealing* neste mesmo caso de agrupamento pelo Algoritmo Genético, obteve-se um resultado igual de 27,04 km para distância total percorrida, porém com um tempo de processamento computacional de 13,35 segundos para as duas etapas. O que representa em relação a situação atual de roteirização empregada pela empresa ABC, onde as 5 rotas totalizam 42,61 km, uma redução de deslocamento de aproximadamente 36,54%. Além dessa redução, há a homogeneização da carga de jornais a ser distribuída em cada rota bem como respeito a restrição de capacidade de 100 jornais por rota, condição que não é respeitada na roteirização atual empregada pela empresa.

Caso se considere o método que performou com pior valor para o deslocamento total, PLF por T&B + FFD min. distância + PCV por Inserção do vizinho mais próximo, que resultou em uma distância total de 35,6 km, mesmo assim seria possível uma redução de 16,45% no deslocamento do entregador. E caso o tempo de processamento fosse levado exclusivamente como fator decisor de método a ser escolhido, o método que teve o menor tempo de processamento computacional foi a resolução do PLF por T&B + FF min. Distância e do PVC o pela Inserção do mais barato (com um tempo de 1,1 s para execução das duas etapas), totalizando um deslocamento de 30,72 km, representado uma redução possível de 27,90%.

5.6.2 Em relação as instâncias da literatura

Para analisar os resultados obtidos pelos testes nas instâncias do PLF, é possível separar as instâncias de teste em 3 grupos em função do número de pontos (n) a serem agrupados em: (1) menor que 50, (2) menor que 100 e (3) de 100 a 402 pontos. A TABELA 13 apresenta os valores médios de erro % e de tempo de execução para cada um dos grupos citados em função de (n). É possível perceber que o melhor desempenho médio geral foi dos métodos meta-heurísticos Algoritmo Genético e *Simulated Annealing* e que o desempenho foi ainda melhor em termos de menor erro % nos casos de maior quantidade de pontos ($100 < n \leq 402$). Adicionalmente os métodos heurísticos tem um tempo de processamento computacional expressivamente maior quando o terceiro grupo é levado em conta ($100 < n \leq 402$) enquanto para os dois outros casos de grupos ($n < 50$ e $n > 100$) são os métodos de menor tempo de processamento.

TABELA 13 - VALORES MÉDIOS POR CATEGORIA EM FUNÇÃO DO NÚMERO DE PONTOS PARA INSTÂNCIA DO PLF

Método	Pontos (n)	Medianas (p)	Pontos (n)	Medianas (p)	Pontos (n)	Medianas (p)
	50	5	100	10	100 a 402	10 a 40
	Erro % médio	Tempo Médio (s)	Erro % médio	Tempo Médio (s)	Erro % médio	Tempo Médio (s)
T&B + G&J Modificado	6,87	0,79	11,63	1,13	13,01	250,28
T&B + VOGEL	10,07	0,14	12,43	2,17	41,41	241,55
T&B + FF (min. distância)	14,25	0,08	14,76	1,64	14,64	230,06
T&B + FFD (min. distância)	21,84	0,07	24,40	1,69	14,63	256,08
Algoritmo Genético	2,34	6,18	3,03	14,48	1,42	43,98
<i>Simulated Annealing</i>	2,40	18,66	3,51	26,51	1,01	71,25

FONTE: A autora (2019).

A TABELA 14 apresenta os valores médio de erro % e de tempo obtido em relação a todas as instâncias por método. Desta forma, é possível identificar que o melhor método para resolução das instâncias de teste do PLF corresponde ao Algoritmo Genético cujo erro % médio é de 2,26% com o menor tempo médio de processamento computacional de 21,54 segundos.

TABELA 14 - RESULTADOS MÉDIOS POR MÉTODO DE RESOLUÇÃO APLICADOS AS INSTÂNCIAS DO PLF

Método	Erro % médio por método	Tempo médio por método (s)
T&B + G&J Modificado	10,50	84,07
T&B + VOGEL	21,30	81,28
T&B + FF (min. distância)	14,55	77,26
T&B + FFD (min. distância)	20,29	85,95
Algoritmo Genético	2,26	21,54
<i>Simulated Annealing</i>	2,31	38,80

FONTE: A autora (2019).

Em relação às instâncias de teste do PCVA, também é possível separar as instâncias de teste em 3 grupos em função do número de pontos a serem percorridos em (1) pequenas ($n < 50$), (2) médias ($50 \leq n \leq 100$) e (3) grandes ($n > 100$). A TABELA 15 apresenta os valores médios obtidos para cada um dos grupos de instâncias em relação a cada método testado para o PCVA. É possível perceber que para as instâncias pequenas e médias o método com menor valor de erro % médio corresponde ao *Simulated Annealing*, enquanto para instâncias grandes o melhor método corresponde ao método heurístico dos *Savings*. Em termos de tempo de processamento computacional os métodos heurísticos tem um tempo bem menor que os métodos meta-heurísticos para todos os conjuntos de instâncias exceto para o método dos *Savings* nas instâncias grandes ($n > 100$).

TABELA 15 - VALORES MÉDIOS POR CATEGORIA EM FUNÇÃO DO NÚMERO DE PONTOS PARA INSTÂNCIA DO PCVA

MÉTODO	Pequena (n <50)		Média (50<= n <=100)		Grande (n>100)	
	Erro % médio	Tempo Médio (s)	Erro % médio	Tempo Médio (s)	Erro % médio	Tempo Médio (s)
<i>Savings</i>	5,13	0,42	9,06	1,52	6,40	630,70
Inser.do + proximo	6,48	0,003	8,85	0,018	12,83	0,74
Inser. do + distante	2,10	0,001	5,68	0,014	14,34	0,78
Inser.do + barato	5,45	0,001	11,13	0,010	17,63	0,21
Inser.do viz. + prox.	12,21	0,000	21,20	0,000	21,42	0,01
Algoritmo Genético	1,14	5,465	3,86	24,840	9,19	472,74
<i>Simulated Annealing</i>	0,37	14,574	2,91	22,778	9,42	659,88

FONTE: A autora (2019).

A TABELA 16 apresenta os valores médios de erro % e de tempo obtido em relação a todas as instâncias por método de resolução do PCVA. Assim, é possível identificar que o melhor método para resolução das instâncias de teste do PCVA corresponde ao *Simulated Annealing* cujo erro % médio é de 4,23%, porém apresenta o maior tempo médio de processamento computacional de 232,41 segundos.

TABELA 16 - RESULTADOS MÉDIOS POR MÉTODO DE RESOLUÇÃO APLICADOS AS INSTÂNCIAS DO PCVA

Método	Erro % médio por método	Tempo médio por método (s)
<i>Savings</i>	6,86	210,88
Inser.do + proximo	9,39	0,25
Inser. do + distante	7,38	0,27
Inser.do + barato	11,40	0,07
Inser.do viz. + prox.	18,28	0,00
Algoritmo Genético	4,73	167,68
<i>Simulated Annealing</i>	4,23	232,41

FONTE: A autora (2019).

6 CONSIDERAÇÕES FINAIS

Este trabalho aborda uma metodologia em duas etapas, sendo 1- Agrupamento (PLF) e 2- Subsequente roteirização (PCVA), possível de ser adotada nos mais diversos problemas de entrega e/ou coleta de mercadorias. Adicionalmente, o estudo mostra o comparativo em termos de qualidade de solução e tempo de processamento computacional entre diversos métodos (exato, heurísticos e meta-heurísticos) para resolução de um PRV.

A partir da revisão de literatura foi possível verificar que a utilização de heurísticas e meta-heurísticas para a resolução do PLF e do PCVA tem apresentado resultados satisfatórios. Assim, mediante a grande quantidade de procedimentos utilizados na literatura, este trabalho comparou, por meio da resolução de um estudo de caso para entrega de jornais no município de Curitiba, 40 diferentes abordagens de resolução.

Para a obtenção das 40 abordagens de resolução, foram aqui utilizados os modelos matemáticos do PLF e do PCVA, apresentados respectivamente nas equações de (1) a (6) e de (12) a (16), métodos heurísticos de Teitz & Bart, Gillett e Johnson modificado, Vogel, *First-Fit*, *First-Fit-Decreasing*, *Savings* de Clarke & Wright e métodos de inserção para criação de rotas. Também, os métodos meta-heurísticos do Algoritmo Genético e *Simulated Annealing*.

Em relação aos resultados obtidos para as instâncias da literatura utilizadas na validação dos algoritmos implementados, o melhor desempenho médio geral foi dos métodos meta-heurísticos AG e SA, tanto na resolução das instâncias do PLF quanto do PCVA. Em termos de tempo médio de resolução por método, no caso do PLF, os métodos meta-heurísticos AG e SA foram os melhores (menor tempo de processamento). Para o PCVA, os métodos mais rápidos foram os algoritmos de inserção.

Os resultados do estudo de caso para entrega de jornais mostram que é possível obter uma redução no deslocamento atualmente realizado pelo entregador de 36,54% quando aplicada a metodologia de resolução proposta em duas fases (1- Agrupamento e 2- Subsequente roteirização) por meio do método meta-heurístico AG para ambas etapas. O uso de procedimentos heurísticos e/ou meta-heurísticos para otimização de problemas reais se mostra muito benéfico mediante o fato de que até

na combinação de métodos que apresentaram piores resultados (Etapa 1 - algoritmo de T&B para definição das medianas e alocação por *First-Fit-Decreasing* seguido de Etapa 2 - roteirização por Inserção do vizinho mais próximo) ainda é possível uma redução de 16,45% do deslocamento em relação a situação atual. Demonstrando assim que, as aplicações de técnicas da PO podem trazer muitas vantagens em termos de redução de custo e melhoria de processos para a resolução de problemas de empresas e organizações.

É importante ressaltar que o uso de procedimentos heurísticos e meta-heurísticos não se dá apenas ao nível estratégico da organização (planejamento de longo prazo), podendo ser aplicados ao nível operacional (planejamento de curto prazo) como é o caso aqui apresentado para planejamento de rotas de entrega.

Os métodos que apresentaram melhor desempenho, em termos de minimização da distância total a ser percorrida, correspondem àqueles que precisaram de um tempo de processamento computacional maior. Porém cabe salientar que os métodos heurísticos e meta-heurísticos correspondem a uma alternativa aos métodos de resolução exatos uma vez que o tempo para resolução dos modelos exatos cresce exponencialmente em função da quantidade de pontos (clientes) envolvidos.

Do ponto de vista metodológico, como estímulo para trabalhos futuros sugere-se a utilização de outros métodos meta-heurísticos, de forma híbrida ou “puros” como, por exemplo, o *Iterated Local Search* (ILS) e/ou *Ant Colony Optimization* (ACO) para análise e comparação aos resultados aqui obtidos. Também a utilização de outras bases para os testes em instâncias da literatura, tanto para o PLF, assim como para o PCVA.

REFERÊNCIAS

- AHMED, Z. H. The Ordered Clustered Travelling Salesman Problem: A Hybrid Genetic Algorithm. **Scientific World Journal**, v. 2014, p. 1–15, 2014.
- ARENALES, M.; ARMENTANO, V.; MORABITO, R.; YANASSE, H. **Pesquisa Operacional para cursos de Engenharia**. Rio de Janeiro: Elsevier, 2011.
- AZIZ, Z. A. Ant Colony Hyper-heuristics for Travelling Salesman Problem. **Procedia Computer Science**, v. 76, p. 534–538, 2015. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S187705091503834X>>. .
- BELFIORE, P.; FÁVERO, L. P. **Pesquisa Operacional para cursos de Engenharia**. 1º ed. Rio de Janeiro: Elsevier, 2013.
- BODIN, L.; GOLDEN, B.; ASSAD, A.; BALL, M. Routing and scheduling of vehicles and crews: the state of the art. **Computers e Operational Research**, v. 10, n. 2, p. 63–211, 1983.
- BOUMAN, P.; AGATZ, N.; SCHMIDT, M. Dynamic programming approaches for the traveling salesman problem with drone. **Networks**, v. 72, n. 4, p. 528–542, 2018.
- BOWERSOX, D. J.; CLOSS, D. J.; COOPER, M. B. BOWERSOX, J. C. **Gestão Logística da Cadeia de Suprimentos**. 4º ed. Porto Alegre: AMGH Editora, 2014.
- BOZORG-HADDAD, O.; SOLGI, M.; LOÁICIGA, H. A. **Meta-heuristic and Evolutionary Algorithms for Engineering Optimization**. 1º ed. Hoboken: John Wiley & Sons, 2017.
- BRAGA, I. P. C.; TEIXEIRA, M. S.; DANTAS, H. F. B.; OLIVEIRA, M. S. B. **Aplicação Do Problema Do Caixeiro Viajante (PCV) Em Uma Empresa Do Ramo Salineiro Do RN**. Anais do ENEGEP, 2015. Fortaleza (CE), out. 2015. Disponível em: <http://www.abepro.org.br/biblioteca/TN_STP_206_222_27622.pdf%3E> Acesso em: 21 Fevereiro 2019.
- BUZNA, L.; KOHÁNI, M.; JANÁČEK, J. An approximation algorithm for the facility location problem with lexicographic minimax objective. **Journal of Applied Mathematics**, v. 2014, 2014. Hindawi Publishing Corporation.
- BYRKA, J.; LI, S.; RYBICKI, B. Improved Approximation Algorithm for k-level Uncapacitated Facility Location Problem (with Penalties). **Theory of Computing Systems**, v. 58, n. 1, p. 19–44, 2016. Springer New York LLC.
- CABRERA G., G.; CABRERA, E.; SOTO, R.; et al. A hybrid approach using an Artificial Bee algorithm with mixed integer programming applied to a large-scale capacitated facility location problem. **Mathematical Problems in Engineering**, v. 1, 2012.
- CACCHIANI, V.; HEMMELMAYR, V. C.; TRICOIRE, F. A set-covering based heuristic algorithm for the periodic vehicle routing problem. **Discrete Applied Mathematics**, v. 163, n. 1, p. 53–64, 2014.

CACCHIANI, V.; MALANDRI, C.; MANTETCCHINI, L.; PAGANELLI, F. A study on the optimal aircraft location for human organ transportation activities. **Transportation Research Procedia**, v. 30, p. 314–323, 2018.

CAMACHO-VALLEJO, J.-F.; CORDERO-FRANCO, Á. E.; GONZÁLEZ-RAMÍREZ, R. G. Solving the bilevel facility location problem under preferences by a stackelberg-evolutionary algorithm. **Mathematical Problems in Engineering**, v. 2014, 2014. Hindawi Publishing Corporation.

CATTARUZZA, D.; ABSI, N.; FEILLET, D.; GONZÁLEZ-FELIU, J. Vehicle routing problems for city logistics. **EURO Journal on Transportation and Logistics**, v. 6, n. 1, p. 51–79, 2017.

CHENG, C.-B.; MAO, C.-P. A modified ant colony system for solving the travelling salesman problem with time windows. **Mathematical and Computer Modelling**, v. 46, n. 9–10, p. 1225–1235, 2007.

CHOWDHURY, S.; MARUFUZZAMAN, M.; TUNC, H.; BIAN, L.; BULLINGTON, W. A Modified Ant Colony Optimization Algorithm to Solve A Dynamic Traveling Salesman Problem: A Case Study with Drones for Wildlife Surveillance. **Journal of Computational Design and Engineering**, 2018.

CLARKE, G.; WRIGHT, J. W. Scheduling of Vehicles from a Central Depot to a Number of Delivery Points. **Operations Research**, v. 12, n. 2, p. 568–581, 1964.

CONTRERAS-BOLTON, C.; PARADA, V. Automatic Combination of Operators in a Genetic Algorithm to Solve the Traveling Salesman Problem. **PLOS ONE**, v. 10, n. 9, 2015.

COOPER, D.; SCHINDLER, P. **Métodos de Pesquisa em Administração**. 12º ed. Porto Alegre: McGraw Hill Brasil, 2016.

CORREA, E. S. Algoritmo Genético e Busca Tabu aplicados ao problema das p-medianas. , 2000. Curitiba: Dissertação de mestrado, Programa de Pós-Graduação em Métodos Numéricos em Engenharia, Universidade Federal do Paraná.

DANTZIG, G. B.; FULKERSON, D. R.; JOHNSON, S. M.; COOK, W. Solution of a Large-Scale Traveling- Salesman Problem. **Operations Research**, v. 2, p. 393–410, 1954.

DANTZIG, G. B.; RAMSER, J. H. The Truck Dispatching Problem. **Management Science**, v. 6, n. 1, p. 80–91, 1959. Disponível em: <<http://pubsonline.informs.org/doi/abs/10.1287/mnsc.6.1.80>>.

DELAHAYE, D.; CHAIMATANAN, S.; MONGEAU, M. Simulated annealing : From basics to applications. In: M. Gendreau; J.-Y. Potvin (Orgs.); **Handbook of Metaheuristics**. 3º ed, p.1–43, 2019. Switzerland: Springer, International Series in Operations Research & Management Science, vol 272.

DENG, Y.; LIU, Y.; ZHOU, D. An Improved Genetic Algorithm with Initial Population Strategy for Symmetric TSP. **Mathematical Problems In Engineering**, 2015.

DJENIĆ, A.; MARIĆ, M.; STANIMIROVIĆ, Z.; STANOJEVIĆ, P. A variable neighbourhood search method for solving the long-term care facility location problem. **IMA Journal of Management Mathematics**, v. 28, n.2, p. 321-338, 2016.

DONG, Y.; WANG, J.; CHEN, F.; HU, Y.; DENG, Y. Location of Facility Based on Simulated Annealing and “ZKW” Algorithms. **Mathematical Problems in Engineering**, v. 2017, 2017. Hindawi.

DÓSA, G., EPSTEIN, L. The tight asymptotic approximation ratio of First Fit for bin packing with cardinality constraints. **Journal of Computer and System Sciences**, v. 96, p. 33–49, 2018.

EISELT, H. A.; MARIANOV, V. **Foundations of Location Analysis**. 1^o ed. New York: Springer Science & Business Media, 2011.

EL-SAMAK, A. F.; ASHOUR, W. Optimization Of Traveling Salesman Problem Using Affinity Propagation Clustering And Genetic Algorithm. **Journal Of Artificial Intelligence And Soft Computing Research**, v. 5, n. 4, p. 239–245, 2015.

EZZATNESHAN, A. A algorithm for the Vehicle Problem. **International Journal Of Advanced Robotic Systems**, v. 7, n. 2, p. 125–132, 2010.

FERREIRA, J. C. **Abordagem Heurística E Meta-Heurística Na Otimização Do Processo Operacional De Uma Empresa De Transportes Rápidos**, 2016. Curitiba: Dissertação de mestrado, Programa de Pós-Graduação em Engenharia de Produção e Sistemas, Pontifícia Universidade Católica Do Paraná.

FERREIRA, V. E. S.; ALMEIDA, A. C. P.; PAULA, M. F. R.; TABOSA, C. M. **Proposta de uma modelagem utilizando PRV para otimização do roteamento da coleta seletiva em Mossoró - RN**. Anais do ENEGEP, 2015. Fortaleza (CE), out. 2015. Disponível em: <www.abepro.org.br/biblioteca/TN_STO_211_250_27141.pdf>3E.> Acesso em: 21 Fevereiro 2019.

FONSECA, J. J. S. **Metodologia da pesquisa científica**. São Carlos: Serviço de Biblioteca e Informação, 2002.

FRANZIN, A.; STUTZLE, T. Revisiting simulated annealing: A component-based analysis. **Computers and Operations Research**, v. 104, p. 191–206, 2019.

FUENTES, G. E. A.; GRESS, E. S. H.; MORA, J. C. S. T.; MARÍN, J. M. Solution to travelling salesman problem by clusters and a modified multi-restart iterated local search metaheuristic. **PLoS ONE**, v. 13, n. 8, 2018. Public Library of Science.

GABOR, A. F.; VAN OMMEREN, J.-K. C. W. A new approximation algorithm for the multilevel facility location problem. **Discrete Applied Mathematics**, v. 158, n. 5, p. 453–460, 2010.

GAN, M.; LI, D.; WANG, M.; et al. Optimal Urban Logistics Facility Location with Consideration of Truck-Related Greenhouse Gas Emissions: A Case Study of Shenzhen City. **Mathematical Problems In Engineering**, 2018.

GAN, M.; LI, D.; WANG, M.; et al. Optimal Urban Logistics Facility Location with Consideration of Truck-Related Greenhouse Gas Emissions: A Case Study of Shenzhen City. **Mathematical Problems in Engineering**, v. 2018, 2018.

GANSTERER, M.; HARTL, R. F.; SALZMANN, P. E. H. Exact solutions for the collaborative pickup and delivery problem. **Central European Journal of Operations Research**, v. 26, n. 2, p. 357–371, 2018.

GLOVER, F. Future paths for integer programming and links to artificial intelligence. **Computers and Operations Research**, v. 13, p. 533–549, 1986.

GOLDBARG, M.; LUNA, H. P.; GOLDBARG, E. **Programação linear e fluxos em redes**. 1º ed. Rio de Janeiro: Elsevier, 2016.

GOLDBERG, D. E. **Genetic algorithms in search, optimization, and machine learning**. 1º ed. Boston: Addison-Wesley, 1989.

GONÇALVES, S. M.; STEINER, M. T. A.; SOUZA, L. V. Metodologia para o PRV: um Estudo de Caso para a Distribuição de Água Mineral. In: M. T. A. Lopes, H. S.; RODRIGUES, L. C. A.; STEINER (Org.); **Meta-Heurísticas em Pesquisa Operacional**. 1º ed, p.203–218, 2013. Curitiba: Omnipax. Disponível em: <<http://omnipax.com.br/livros/2013/MHPO/mhpo-cap13.pdf>>. .

HAI RACHID, M. **Les problèmes de tournées de véhicules en planification industrielle : classification et comparaison d ' opérateurs évolutionnaires**, 2010. Besançon: Tese (doutorado) – Ecolé Doctorale SPIM Spécialité Informatique.

HASHIMOTO, H.; YAGIURA, M.; IBARAKI, T. An iterated local search algorithm for the time-dependent vehicle routing problem with time windows. **Discrete Optimization**, v. 5, n. 2, p. 434–456, 2008. Netherlands: Elsevier Science BV.

HASSANAT, A. B.; PRASATH, V. B. S.; ABBADI, M. A.; ABU-QDARI, S. A.; FARIS, H. An improved Genetic Algorithm with a new initialization mechanism based on Regression techniques. **Information (Switzerland)**, v. 9, n. 7, 2018.

HEILPORN, G.; CORDEAU, J.-F.; LAPORTE, G. The Delivery Man Problem with time windows. **Discrete Optimization**, v. 7, n. 4, p. 269–282, 2010.

HIRSCH, J. E. An index to quantify an individual's scientific research output. **Proceedings of the National Academy of Sciences of the United States of America**, v. 102, n. 4, p. 16569–16572, 2005. Disponível em: <<http://arxiv.org/abs/physics/0508025>><http://dx.doi.org/10.1073/pnas.0507655102>>. .

HOEKSTRA, G.; PHILLIPSON, F. Heuristic Approaches for Location Assignment of Capacitated Services in Smart Cities. **COMPUTERS**, v. 7, n. 4, 2018.

HOEKSTRA, G.; PHILLIPSON, F. Heuristic approaches for location assignment of capacitated services in smart cities. **Computers**, v. 7, n. 4, 2018.

HOLLAND, J. H. **Adaptation in Natural and Artificial Systems**. 1º ed. Ann Arbor: University of Michigan Press, 1975.

HU, Y.; ZHANG, K.; YANG, J.; WU, Y. Application of Hierarchical Facility Location-Routing Problem with Optimization of an Underground Logistic System: A Case Study in China. **Mathematical Problems In Engineering**, 2018.

HUSSAIN, A.; MUHAMMAD, Y. S.; SAJID, M. N.; et al. Genetic Algorithm for Traveling Salesman Problem with Modified Cycle Crossover Operator. **Computational Intelligence and Neuroscience**, 2017.

IBGE. Pesquisa Anual de Serviços (PAS), 2018. Rio de Janeiro: Instituto Brasileiro de Geografia e Estatística. Disponível em: <[%3E](https://sidra.ibge.gov.br/pesquisa/pas/tabelas)>. Acesso em: 10 Fevereiro 2019.

ISCAN, H.; GUNDUZ, M. An application of fruit fly optimization algorithm for traveling salesman problem. **Procedia Computer Science**, v. 111, p. 58–63, 2017.

JAFARZADEH, H.; MORADINASAB, N.; ELYASI, M. An Enhanced Genetic Algorithm for the Generalized Traveling Salesman Problem. **Engineering Technology & Applied Science Research**, v. 7, n. 6, p. 2260–2265, 2017.

JUN-MAN, K.; YI, Z. Application of an Improved Ant Colony Optimization on Generalized Traveling Salesman Problem. **Energy Procedia**, v. 17, Part A, p. 319–325, 2012.

KARATAS, M.; RAZI, N.; TOZAN, H. A Comparison of p-median and Maximal Coverage Location Models with Q-coverage Requirement. **Procedia Engineering**, v. 149, p. 169–176, 2016.

KARP, R. M. Reducibility among Combinatorial Problems. In: B. J. D. Miller R.E., Thatcher J.W. (Org.); **Complexity of Computer Computations**. p.85–103, 1972. Boston: The IBM Research Symposia Series. Springer.

KIRKPATRICK, S.; GELATT, C. D.; VECCHI, M. P. Optimization by Simulated Annealing. **Science**, v. 220, n. 4598, 1983.

KORAC, V.; KRATICA, J.; SAVIC, A. An Improved Genetic Algorithm for the Multi Level Uncapacitated Facility Location Problem. **International Journal Of Computers Communications & Control**, v. 8, n. 6, p. 845–853, 2013.

KRATICA, J.; DUGOŠIJA, D.; SAVIĆ, A. A new mixed integer linear programming model for the multi level uncapacitated facility location problem. **Applied Mathematical Modelling**, v. 38, n. 7–8, p. 2118–2129, 2014. Elsevier Inc.

KRIPKA, R. M. L.; KRIPKA, L. Simulated Annealing Aplicado ao Problema de Alocação de Salas com Deslocamentos Mínimos. In: M. T. A. Lopes, H. S.; RODRIGUES, L. C. A.; STEINER (Org.); **Meta-Heurísticas em Pesquisa Operacional**. 1º ed, p.325–338, 2013. Curitiba: Omnipax.

LAGOS, C.; GUERRERO, G.; CABRERA, E.; et al. A Matheuristic Approach Combining Local Search and Mathematical Programming. **Scientific Programming**, v. 2016, 2016. Hindawi Limited.

LAGUNA, M. Tabu Search. In: R. Martí; P. M. Pardalos; M. G. C. Resende (Orgs.); **Handbook of Heuristics**. 1º ed, p.741–758, 2018. Cham: Springer.

LAPORTE, G. Fifty years of vehicle routing. **Transportation Science**, v. 43, n. 4, p. 408–416, 2009. INFORMS, Inst.for Operations Res.and the Management Sciences.

LAPORTE, G. A concise guide to the Traveling Salesman Problem. **Journal of the Operational Research Society**, v. 61, n. 1, p. 35–40, 2010.

LEITE, O.; GOMES, C. Problema de roteamento de veículos com coleta e entrega simultâneas : um estudo de caso em uma indústria de alimentos localizada na região do vale do aço. **Revista Latino-Americana de Inovação e Engenharia de Produção**, v. 5, n. 7, p. 101–115, 2017.

LIAO, Y.-F.; YAU, D.-H.; CHEN, C.-L. Evolutionary algorithm to traveling salesman problems. **Computers & Mathematics with Applications**, v. 64, n. 5, p. 788–797, 2012.

LIN, A. S.; KERNIGHAN, B. W. An Effective Heuristic Algorithm for the Traveling-Salesman Problem. **Operations Research**, v. 21, n. 2, p. 498–516, 1973.

LIN, B. S. Computer Solutions of the Traveling Salesman Problem. **Bell Sytem Tech. J**, v. 44, n. 10, p. 2245–2269, 1965.

MAJUMDAR, J.; BHUNIA, A. K. Genetic algorithm for asymmetric traveling salesman problem with imprecise travel times. **Journal of Computational and Applied Mathematics**, v. 235, n. 9, p. 3063–3075, 2011. Elsevier B.V. Disponível em: <<http://dx.doi.org/10.1016/j.cam.2010.12.027>>. .

MAVROVOUNIOTIS, M.; MULLER, F. M.; YANG, S. Ant Colony Optimization With Local Search for Dynamic Traveling Salesman Problems. **IEEE Transactions On Cybernetics**, v. 47, n. 7, p. 1743–1756, 2017.

MELO, T.; NICKEL, S.; GAMA, F. S. DA. Facility Location and Supply Chain Management – A comprehensive review. **Berichte des Fraunhofer ITWM**, v. 130, n. 130, p. 1–63, 2007.

MESTRIA, M.; OCHI, L. S.; MARTINS, S. DE L. GRASP with path relinking for the symmetric Euclidean clustered traveling salesman problem. **Computers & Operations Research**, v. 40, n. 12, p. 3218–3229, 2013.

METROPOLIS, N.; ROSENBLUTH, A. W.; ROSENBLUTH, M. N.; TELLER, A. H.; TELLER, E. Equation of State Calculations by Fast Computing Machines. **The Journal Of Chemical Physics**, v. 21, n. 6, p. 1087–1092, 1953.

MIGUEL, P. A. C.; FLEURY, A.; MELLO, C. H. P.; et al. **Metodologia de pesquisa em engenharia de produção e gestão de operações**. 2º ed. Rio de Janeiro: Elsevier, 2012.

MIRJALILI, S. **Evolutionary Algorithms and Neural Networks**. 1º ed. Brisbane: Springer International Publishing AG, part of Springer Nature 2019, 2019.

MOHSEN, A. M. Annealing Ant Colony Optimization with Mutation Operator for Solving TSP. **Computational Intelligence And Neuroscience**, 2016.

ODILI, J. B.; KAHAR, M. N. M. Solving the Traveling Salesman's Problem Using the African Buffalo Optimization. **COMPUTATIONAL INTELLIGENCE AND NEUROSCIENCE**, 2016.

OSMAN, I.; CHRISTOFIDES, N. Capacitated clustering problems by hybrid simulated annealing and tabu search, **International Transactions in Operational Research**, v.1, n. 3, p 317-336, 1994.

PINTEA, C.-M.; POP, P. C.; CHIRA, C. The Generalized Traveling Salesman Problem solved with Ant Algorithms. **Complex Adaptive Systems Modeling**, v.5, n.8, p. 1-9, 2013.

POONTHALIR, G.; NADARAJAN, R. A. A Fuel Efficient Green Vehicle Routing Problem with varying speed constraint (F-GVRP). **Expert Systems with Applications**, v. 100, p. 131–144, 2018.

POP, P. C.; KARA, I.; MARC, A. H. New mathematical models of the generalized vehicle routing problem and extensions. **Applied Mathematical Modelling**, v. 36, n. 1, p. 97–107, 2012. New York, Elsevier Science Inc.

QIN, J.; NI, L.; SHI, F. Combined Simulated Annealing Algorithm for the Discrete Facility Location Problem. **The Scientific World Journal**, v. 2012, p. 1–7, 2012. Disponível em: <<http://www.hindawi.com/journals/tswj/2012/576392/>>. .

RAZALI, N. M. An Efficient Genetic Algorithm for Large Scale Vehicle Routing Problem Subject to Precedence Constraints. **Procedia - Social and Behavioral Sciences**, v. 195, p. 1922–1931, 2015. Elsevier B.V.

REEVES, C. R. Genetic Algorithms. In: M. Gendreau; J.-Y. Potvin (Orgs.); **Handbook of Metaheuristics**. 2º ed, p.109–139, 2010. Switzerland: SPRINGER.

REGO, C.; GLOVER, F. Local Search and Metaheuristics. In: G. Gutin; A. P. Punnen (Orgs.); **The Traveling Salesman Problem and Its Variations. Combinatorial Optimization**, vol 12. p.309–368, 2007. Boston: Springer.

ROSENKRANTZ, D. J.; STEARNS, R. E.; LEWIS, P. M. An analysis of several heuristics for the Traveling Salesman Problem. **SIAM Journal on Computing**, v. 6, n. 3, p. 563–581, 1977.

SANTOS, C. I. G.; GUERSOLA, M, DE S. FERREIRA, J. C.; STEINER, M. T. A. Otimização do Processo Operacional de Uma Administradora De Condomínios: Um Estudo De Caso. Anais do ENEGEP, 2016. João Pessoa (PB), out. 2016. Disponível em: <www.abepro.org.br/biblioteca/TN_STO_211_250_27141.pdf>. Acesso em: 21 Fevereiro 2019.

SENNE, E. L. F.; LORENA, L. A. N. Abordagens complementares para problemas de p-medianas. **Produção**, v. 13, n. 3, p. 78–87, 2003.

SHEU, J. H. A hybrid fuzzy-optimization approach to customer grouping-based logistics distribution operations. **Applied Mathematical Modelling**, v. 31, n. 6, p. 1048–1066, 2007. New York: Elsevier Science Inc.

SILVA, F. A. V. **Um algoritmo genético para o Problema de Roteamento de Veículos com janela de tempo aplicado na distribuição de serviços de telecomunicação**, 2016. Fortaleza: Dissertação (Mestrado em Ciências) - Setor de Logística e Pesquisa Operacional, Universidade Federal do Ceará.

DA SILVA, R. F.; URRUTIA, S. A General VNS heuristic for the traveling salesman problem with time windows. **Discrete Optimization**, v. 7, n. 4, p. 203–211, 2010.

SOUSA, R. G.; KLOECKNER, N. V. R. Aplicação do problema de roteamento de veículos classico (PRVC) na empresa SIGMA. **Revista de Engenharia da UNI7**, v. 1, n. 1, p. 187–288, 2017.

SUNG, J.; JEONG, B. An Adaptive Evolutionary Algorithm for Traveling Salesman. **The Scientific World Journal**, v. 2014, p. 1–11, 2014.

TADEI, R.; PERBOLI, G.; PERFETTI, F. The multi-path Traveling Salesman Problem with stochastic travel costs. **Euro Journal On Transportation and Logistics**, v. 6, n. 1, SI, p. 3–23, 2017.

TEITZ, M. B.; BART, P. Heuristic Methods for Estimating the Generalized Vertex Median of a Weighted Graph. **Operations Research**, v. 16, n. 5, p. 955–961, 1968. Disponível em: <<http://dx.doi.org/10.1287/opre.16.5.955>>. .

ULUKAN, Z.; DEMIRCIOĞLU, E. A Survey of Discrete Facility Location Problems. **International Journal of Industrial and Manufacturing Engineering**, v. 9, n. 7, p. 2487–2492, 2015.

UMBARKAR, A. J.; SHETH, P. D. Crossover Operators in Genetic Algorithms. **ICTACT Journal on Soft Computing**, v. 6, n. 1, p. 1083–1092, 2015.

VALIDI, S.; BHATTACHARYA, A.; BYRNE, P. J. A solution method for a two-layer sustainable supply chain distribution model. **Computers & Operations Research**, v. 54, p. 204–217, 2015.

VIANA, A. V. D.; ROBOREDO, M. C. **Roteamento de carros terceirizados em uma operadora logística ferroviária: um estudo de caso**, 2016. Niterói - RJ: Monografia (Graduação em Engenharia de Produção) - Universidade Federal Fluminense.

WHITLEY, D. Next Generation Genetic Algorithms: A User's Guide and Tutorial. In: M. Gendreau; J.-Y. Potvin (Orgs.); **Handbook of Metaheuristics**. 3º ed, p.244–274, 2019. Switzerland: Springer, International Series in Operations Research & Management Science, vol 272.

WICHAPA, N.; KHOKHAJAIKIAT, P. Solving a multi-objective location routing problem for infectious waste disposal using hybrid goal programming and hybrid genetic algorithm. **International Journal of Industrial Engineering Computations**, v. 9, n. 1, p. 75–98, 2018.

XI, M.; YE, F.; YAO, Z.; ZHAO, Q. A modified p -median model for the emergency facilities location problem and its variable neighbourhood search-based algorithm. **Journal of Applied Mathematics**, v. 1, 2013.

XIANG, Z.; CHEN, Z.; GAO, X.; et al. Solving Large-Scale TSP Using a Fast Wedging Insertion Partitioning Approach. **Mathematical Problems In Engineering**, 2015.

XU, H.; PU, P.; DUAN, F. Dynamic Vehicle Routing Problems with Enhanced Ant Colony Optimization. **Discrete Dynamics In Nature and Society**, 2018.

YANG, J.; SHI, X.; MARCHESE, M.; LIANG, Y. Ant colony optimization method for generalized TSP problem. **Progress in Natural Science**, v. 18, n. 11, p. 1417–1422, 2008. Science Press.

YANG, J.; WU, C.; LEE, H. P.; LIANG, Y. Solving traveling salesman problems using generalized chromosome genetic algorithm. **Progress In Natural Science-Materials International**, v. 18, n. 7, p. 887–892, 2008. New York: Elsevier Science Inc.

YOUSSEFIKHOSHBAKHT, M.; DIDEHVAR, F.; RAHMATI, F. An Efficient Solution for the VRP by Using a Hybrid Elite Ant System. **International Journal Of Computers Communications & Control**, v. 9, n. 3, p. 340–347, 2014.

ZHAN, S.; LIN, J.; ZHANG, Z.; ZHONG, Y. List-Based Simulated Annealing Algorithm for Traveling Salesman Problem. **Computational Intelligence And Neuroscience**, 2016.

ZHANG, P. A new approximation algorithm for the k -facility location problem. **Theoretical Computer Science**, v. 384, n. 1, p. 126–135, 2007.

**ANEXO 1 – LISTAGEM DOS 89 ROTEIROS ATENDIDOS PELO DISTRIBUIDOR
DA REGIÃO SUL**

(continua)

Roteiro	Assinantes	JR	J
1020003	11	8	3
1020004	311	176	135
1020005	276	150	126
1020006	248	128	120
1020007	340	194	146
1020008	0	0	0
1020009	322	176	146
1020010	324	184	140
1020016	0	0	0
1020018	86	46	40
1020035	0	0	0
1020045	497	262	235
1020046	465	222	243
1020047	476	270	206
1020049	508	257	251
1020051	320	201	119
1020052	210	122	88
1020053	192	103	89
1020054	403	210	193
1020055	157	97	60
1020056	374	232	142
1020057	72	39	33
1020058	97	62	35
1090001	52	40	12
1090003	56	40	16
1100001	138	50	88
1100002	103	70	33
1100003	91	63	28
1120001	515	301	214
1120002	619	346	273
1120021	351	195	156
1120023	158	72	86
1120031	383	219	164
1120034	576	321	255
1120041	451	275	176
1160001	44	23	21
1160002	8	5	3
1010002	479	217	262
1010003	317	182	135
1010005	614	239	375
1010006	163	70	93
1010008	196	122	74
1010010	212	120	92
1010017	106	57	49
1010019	284	115	169
1010020	375	197	178
1010023	257	140	117
1010024	207	105	102
1010026	193	98	95
1010029	328	158	170
1010030	67	40	27
1010033	203	109	94

(conclusão)

1010034	112	62	50
1010039	18	11	7
1010127	278	129	149
1010131	155	82	73
1010132	223	130	93
1010101	51	33	18
1010113	202	114	88
1010114	121	67	54
1010118	101	55	46
1010119	362	177	185
1010120	131	80	51
1010123	137	76	61
1010124	213	100	113
1010125	264	114	150
1010126	163	83	80
1010129	131	71	60
1010130	63	42	21
1010133	78	50	28
1010135	191	102	89
1010136	185	116	69
1010138	80	50	30
1010139	34	17	17
1050001	38	21	17
1050002	96	67	29
1050003	93	43	50
1050004	167	100	67
1050005	239	127	112
1050006	163	92	71
1050007	136	70	66
1050008	197	113	84
1050009	95	51	44
1050010	44	31	13
1050012	109	50	59
1080002	231	115	116
1080003	111	63	48
1080004	112	51	61
1340002	19	12	7

ANEXO 2 – MATRIZ DE DISTÂNCIAS DE DESLOCAMENTOS REAIS ENTRE OS 35 MACRO PONTOS DE DEMANDA

Pontos	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35
1	0,00	0,60	1,50	2,60	1,70	2,00	1,20	0,65	1,70	3,50	3,40	3,70	1,00	1,30	1,80	1,70	1,50	1,60	1,50	0,70	2,10	1,40	1,00	1,20	3,40	1,10	3,60	2,00	1,40	3,10	3,00	3,00	1,30	0,29	3,00
2	0,15	0,00	1,60	2,60	1,50	2,00	1,20	0,65	1,70	3,40	3,30	3,70	1,00	1,10	1,80	1,30	0,95	1,10	1,50	0,75	2,10	1,40	1,00	1,20	3,30	1,20	3,60	2,00	1,40	3,30	3,00	1,00	1,30	0,45	3,00
3	1,60	1,50	0,00	1,20	0,21	0,60	1,10	1,60	0,55	2,10	2,00	2,30	1,10	1,10	0,35	2,00	1,60	2,00	0,40	1,20	0,75	0,30	1,00	0,90	2,00	1,20	2,20	0,65	1,50	1,70	1,60	1,00	1,00	1,50	1,60
4	3,20	3,10	2,10	0,00	2,10	1,60	2,30	3,20	2,20	1,10	1,00	1,30	2,70	2,30	1,80	3,30	2,90	3,30	2,40	2,80	1,00	2,00	2,60	2,50	1,00	2,50	1,20	1,00	2,80	1,10	0,60	2,60	2,10	3,20	0,60
5	2,10	2,00	0,35	1,00	0,00	0,45	1,20	2,10	0,65	2,00	1,80	2,10	1,20	1,30	0,23	2,10	1,70	2,10	0,55	1,30	0,60	0,45	1,10	1,00	1,90	1,40	2,00	0,50	1,70	1,50	1,40	1,10	1,10	2,10	1,50
6	1,80	1,70	1,00	0,70	0,70	0,00	1,70	1,80	1,10	1,40	1,20	1,80	1,60	1,70	0,75	3,00	2,20	2,80	1,20	1,70	0,30	0,85	1,50	1,40	1,20	1,80	1,80	0,21	2,10	1,20	1,10	1,50	1,50	1,90	2,10
7	2,00	1,90	1,10	2,20	1,30	1,40	0,00	1,40	0,65	3,10	3,00	3,20	0,55	0,23	1,30	1,50	1,10	1,50	1,00	0,70	1,70	0,60	0,60	0,80	3,00	0,75	3,20	1,50	1,00	2,60	2,50	0,60	0,16	1,90	2,60
8	1,80	1,70	0,90	1,90	1,10	1,40	0,60	0,00	1,00	2,90	2,70	3,00	0,35	0,40	1,10	1,20	0,90	1,30	0,80	0,30	1,50	0,75	0,35	0,55	2,80	0,50	2,90	1,40	0,80	2,40	2,30	0,40	0,70	1,70	2,40
9	1,40	1,30	0,45	1,50	0,65	0,90	1,10	1,40	0,00	2,40	2,10	2,60	1,00	1,10	0,70	1,90	1,60	2,30	0,35	1,20	1,00	0,60	1,00	0,85	2,30	1,20	2,50	0,95	1,50	2,00	1,90	1,00	0,95	1,20	1,90
10	2,40	2,30	1,60	0,30	1,30	1,90	2,50	2,40	1,90	0,00	0,60	0,35	2,70	2,80	1,40	0,35	3,20	3,30	1,80	2,50	1,80	1,70	2,80	2,30	0,65	2,90	0,24	1,30	3,20	0,11	0,60	2,80	2,30	2,40	0,60
11	2,50	2,40	1,70	0,40	1,40	2,00	2,70	2,50	2,00	0,35	0,00	0,80	2,80	2,70	1,50	3,60	3,30	3,40	1,90	2,60	1,40	1,80	2,80	2,40	0,65	3,00	0,75	1,40	3,30	0,29	0,70	2,90	2,50	2,50	0,70
12	2,30	2,20	1,60	0,55	1,20	1,70	2,50	2,30	1,90	0,26	0,60	0,00	2,70	2,80	1,30	3,50	3,10	3,30	1,80	2,40	1,80	1,60	2,70	2,20	0,60	2,80	0,45	1,70	3,10	0,15	0,85	2,70	2,30	2,40	0,85
13	2,00	1,80	1,00	2,10	1,20	1,60	0,60	1,20	1,00	3,00	2,90	3,20	0,00	0,40	1,30	1,20	0,90	1,30	1,00	1,60	1,60	0,80	0,50	0,70	2,90	0,50	3,10	1,50	0,80	2,60	2,50	0,50	0,70	1,80	2,50
14	2,00	1,80	1,00	2,10	1,20	1,30	0,40	1,20	0,60	3,00	2,90	3,20	0,35	0,00	1,30	1,20	0,90	1,30	1,00	0,45	1,60	0,55	0,50	0,70	2,90	0,50	3,10	1,40	0,80	2,60	2,50	0,50	0,35	1,80	2,50
15	2,00	1,90	0,70	0,75	0,85	0,35	1,40	2,00	0,75	1,80	1,70	2,00	1,30	1,40	0,00	2,20	1,80	2,20	0,90	1,40	0,45	0,55	1,20	1,10	1,70	1,50	1,90	0,35	1,80	1,40	1,30	1,20	1,20	2,00	1,30
16	1,30	1,70	1,30	2,30	1,50	1,80	0,65	0,80	1,10	3,20	3,10	3,40	0,40	0,50	1,50	0,00	0,45	0,85	1,20	0,60	1,80	0,90	0,70	0,90	0,80	2,20	1,20	2,40	0,80	1,50	1,90	1,80	0,90	1,40	1,80
17	1,70	2,00	1,60	2,60	1,80	2,10	1,30	1,10	1,60	3,60	3,40	3,70	1,00	1,00	1,80	0,60	0,00	0,45	1,50	1,00	2,20	1,50	1,10	1,30	3,50	1,20	3,70	2,10	0,75	3,10	3,00	1,10	1,40	1,90	3,10
18	1,20	1,60	1,20	2,20	1,40	1,60	0,85	0,65	1,30	3,20	3,00	3,30	0,55	0,65	1,40	1,00	0,35	0,00	1,10	0,60	1,80	1,00	0,65	0,85	3,00	0,75	3,20	1,70	1,00	2,70	2,60	0,65	1,50	2,60	
19	1,50	1,40	0,20	1,20	0,30	0,80	1,00	1,60	0,45	2,30	2,20	2,40	1,00	1,10	0,40	1,90	1,50	1,90	0,00	1,10	0,90	0,75	0,90	0,80	2,20	1,20	2,40	0,80	1,50	1,90	1,80	0,90	0,90	1,40	1,80
20	1,80	1,70	0,85	1,90	0,80	1,30	0,75	1,80	1,00	2,80	2,70	3,00	0,50	0,55	1,10	1,70	1,00	1,40	0,55	0,00	1,40	0,70	0,30	0,30	2,70	0,65	2,90	1,30	1,00	2,40	2,30	0,23	0,90	1,60	2,30
21	2,20	2,10	0,90	0,50	1,10	0,40	1,50	2,20	1,00	1,40	1,30	1,60	1,50	1,60	0,65	2,40	2,00	2,40	1,10	1,60	0,00	0,75	1,40	1,30	1,30	1,70	1,50	0,26	2,00	1,30	0,85	1,40	1,40	2,30	0,80
22	1,70	1,60	0,80	1,80	1,00	1,30	0,40	1,20	0,60	2,40	2,30	2,90	0,35	0,40	1,00	1,20	0,90	1,30	0,70	0,45	1,40	0,00	0,25	0,45	2,60	0,50	2,80	1,30	0,80	2,30	2,20	0,26	0,35	1,60	2,20
23	1,40	1,30	0,55	1,60	0,75	1,00	0,75	1,40	0,65	2,50	2,40	2,70	0,70	0,80	0,75	1,60	1,30	1,60	0,45	0,85	1,10	0,40	0,00	0,20	2,40	0,90	2,60	1,00	1,20	2,10	2,00	0,65	0,60	1,30	2,00
24	1,50	1,40	0,55	1,60	0,60	1,00	0,80	1,50	0,70	2,50	2,40	2,70	0,75	0,80	0,80	1,60	1,30	1,70	0,30	0,85	1,10	0,40	0,65	0,00	2,40	0,90	2,60	1,00	1,20	2,10	2,10	0,65	0,60	1,30	2,00
25	2,20	2,10	1,40	0,65	1,10	1,50	2,30	2,20	1,70	0,35	0,45	0,65	2,50	2,60	1,20	3,30	3,00	3,10	1,60	2,30	1,70	1,50	2,60	2,10	0,00	2,70	0,55	1,60	3,00	0,25	1,00	2,60	2,20	2,20	1,00
26	1,90	2,30	1,60	2,70	1,80	1,90	0,75	1,40	1,20	3,60	3,50	3,80	0,90	0,60	1,90	0,70	1,10	0,75	1,60	1,00	2,20	1,10	1,10	1,30	3,50	0,00	3,70	2,00	0,30	3,20	3,10	1,10	0,85	2,20	3,10
27	2,40	2,30	1,70	0,65	1,30	1,70	2,50	2,40	2,00	0,35	0,65	0,01	2,80	2,80	1,40	3,50	3,20	3,40	1,80	2,50	1,90	1,70	2,80	2,30	0,70	2,90	0,00	1,80	3,20	0,24	1,00	2,80	2,40	2,40	1,00
28	2,20	2,00	0,80	0,65	1,00	0,30	1,50	2,20	0,90	1,60	1,50	1,70	1,40	1,50	0,55	2,30	1,90	2,30	1,00	1,50	0,21	0,65	1,30	1,20	1,50	1,60	1,70	0,00	1,90	1,50	1,00	1,30	1,30	2,20	1,10
29	1,60	2,00	1,30	2,40	1,50	1,60	0,45	1,10	0,85	3,30	3,20	3,40	0,60	0,27	1,50	0,90	0,75	0,95	1,20	0,75	1,90	0,80	0,80	1,00	3,20	0,40	3,40	1,70	0,00	2,80	2,70	0,80	0,55	1,90	2,80
30	2,30	2,20	1,50	0,40	1,20	1,60	2,90	2,30	1,80	0,11	0,50	0,40	2,60	2,70	1,30	3,40	3,10	3,20	1,70	2,40	1,70	1,60	2,60	2,20	0,55	2,80	0,30	1,60	3,10	0,00	0,70	2,70	2,20	2,30	0,70
31	2,60	2,50	1,90	0,60	1,50	2,20	3,20	2,60	2,20	0,55	0,40	1,00	3,00	3,10	1,60	3,70	3,40	3,60	2,00	2,70	2,10	1,90	3,00	2,50	0,45	3,10	0,95	2,00	3,40	0,70	0,00	3,00	2,60	2,70	0,90
32	1,60	1,40	0,65	1,70	0,85	1,10	0,60	1,60	0,80	2,60	2,50	2,80	0,55	0,65	0,85	1,40	1,10	1,50	0,55	0,65	1,20	0,50	0,11	0,30	2,50	0,70	2,70	1,10	1,00	2,20	2,10	0,00	0,55	1,40	2,10
33	1,90	1,80	1,00	2,00	1,20	1,20	1,06	1,50	0,50	2,60	2,40	3,10	0,60	0,35	1,20	1,60	1,20	1,60	0,90	0,80	1,50	0,45	0,55	0,60	2,80	0,85	3,00	1,40	1,10	2,50	2,40	0,55	0,00	1,70	2,40
34	0,45	0,30	1,30	2,30	1,50	1,70	1,00	0,35	1,40	3,20	3,10	3,40	0,70	0,75	1,50	1,60	1,20	1,40	1,20	0,45	1,80														